

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

DIPLOMSKI RAD

**ANALIZA PRISUTNOSTI „DUTCH DISEASE“
U REPUBLICI HRVATSKOJ**

Mentor:
doc. dr. sc. Josip Visković

Student:
Maja Bačelić

Split, kolovoz, 2018.

SADRŽAJ:

1. UVOD	3
1.1. Problem i predmet istraživanja	3
1.1.1. Problem istraživanja.....	3
1.1.2. Predmet istraživanja	5
1.2. Ciljevi, struktura i hipoteze istraživanja	6
1.2.1. Ciljevi istraživanja	6
1.2.2. Struktura diplomskoga rada	6
1.2.3. Istraživačke hipoteze	7
1.3. Metode istraživanja	8
1.4. Doprinos istraživanja	8
2. „DUTCH DISEASE“	10
2.1. Pojam „Dutch Disease“	10
2.2. Simptomi „Dutch Disease“	11
2.3. Efekti „Dutch Disease“	13
2.4. Mjere makroekonomske politike za uklanjanje negativnih efekata „Dutch Disease“	15
2.4.1. Monetarna i tečajna politika.....	16
2.4.2. Fiskalna politika	17
2.4.3. Politika potrošnje i strukturna politika	18
3. TEORIJSKI PREGLED ISTRAŽIVANJA O „DUTCH DISEASE“ IZAZVANE NAGLIM RASTOM SEKTORA TURIZMA	19
3.1. Negativan utjecaj volatilnosti valute i neravnotežnog tečaja na ekonomski rast.....	22
3.1.1. Precijenjenost valute	23
3.2. „Spending Effect“	23
3.3. „Resource movement effect“	24
3.4. Sektor turizma u Republici Hrvatskoj.....	26

4. EMPIRIJSKO ISTRAŽIVANJE O POSTOJANJU „DUTCH DISEASE“ U RH	30
4.1. Rast potražnje i priljeva deviza u turističkom sektoru i realna aprecijacija kune.....	30
4.2. Direktna deindustrijalizacija	33
4.2.1. Odnos zaposlenih u „tradable“ sektoru i prihoda od turizma	34
4.2.2. Odnos zaposlenih u „non-tradable“ sektoru i prihoda od turizma	36
4.3. Indirektna deindustrijalizacija	39
4.3.1. Odnos realnog efektivnog tečaja kune i izvoza „tradable“ sektora.....	40
4.3.2. Odnos prosječne plaće i izvoza „tradable“ sektora	42
4.3.3. Odnos prosječne plaće u „tradable“ sektoru i izvoza „tradable“ sektora....	44
4.3.4. Odnos prosječne plaće u „non-tradable“ sektoru i izvoza „tradable“ sektora	45
5. ZAKLJUČAK.....	48
POPIS SLIKA.....	50
POPIS TABLICA	51
LITERATURA	53
SAŽETAK.....	57
SUMMARY.....	58

1. UVOD

1.1. Problem i predmet istraživanja

1.1.1. Problem istraživanja

Pojam Nizozemske bolesti, kako ističe Corden (1984, str. 359), se po prvi puta koristi u „The Economist-u“ 1977. godine kako bi opisao oštar rast blagostanja u Nizozemskoj za vrijeme 1960-ih uzrokovan otkrićem velikih rezervi plina. Nakon otkrića, došlo je do negativnih učinaka na nizozemsku proizvodnju, uglavnom kroz naknadnu aprecijaciju realnog deviznog tečaja. Naime, kako su rasli prihodi od izvoza, tada rastućeg sektora, došlo je do aprecijacije nizozemskog guldena što je imalo negativan efekt na ostale industrije.

Način na koji se porast prihoda od izvoza u nizozemskom slučaju može povezati sa turizmom u Hrvatskoj je pojašnjen u nastavku. Dostupnost prirodnih resursa (poput plaža, nacionalnih parkova, parkova prirode, sunčanog vremena i slično) postaje komparativna prednost turističkog proizvoda i objašnjava zašto su odredišta s tim elementima često specijalizirana u turizmu (Capó, Riera Font i Rosselló Nadal, 2007, str. 616).

Jačanje turističkog sektora nauštrb ostalih sektora karakteristično je za obalne i otočne zemlje. Neke od primjera zemalja su Španjolska, Grčka i Hrvatska. Pregledom dvije različite španjolske regije, Balearskog i Kanarskog otočja, čije su ekonomije jako orijentirane na turizam, Capó, Riera Font i Rosselló Nadal (2007, str. 615) dolaze do zaključka kako oba otočja pokazuju znakove nizozemske bolesti i zbog toga, kako navode, bi njihov gospodarski rast mogao biti ugrožen u narednim godinama.

Bresser-Pereira (2008, str. 60), prema Oomes i Kalcheva, (2007), navodi najvažnije simptome nizozemske bolesti: precijenjenost valute, niske stope rasta proizvodne industrije, umjetno visoke realne plaće i visoka nezaposlenost.

O mogućim negativnim utjecajima naglog rasta sektora turizma u svom radu pišu Chao, Hazari et al. (2006, str. 514). Naime, kako navode autori, ekspanzija turizma povećava cijene „non-tradable“ dobara (usluga), iz čega proizlazi porast prihoda. Budući da turizam „pretvara“ „non-tradable“ dobra u izvozna, povećanje cijena može se očitati kao poboljšanje uvjeta trgovine. Međutim, porast cijena „non-tradable“ dobara potiče re-alokaciju resursa iz proizvodnog sektora. Spomenuto će smanjiti potražnju za domaćim kapitalom, pa tako i akumulaciju kapitala. Smanjenje potražnje, stavlja dalje pritisak na proizvodni sektor i rezultira pojavom nizozemske bolesti i deindustrijalizacijom. Postojanje eksternalija će

dodatno pogoršati efekt deindustrijalizacije, čineći tako turizam sektorom koji će negativno utjecati na blagostanje.

Mogući pozitivni utjecaji nizozemske bolesti, kako navodi Corden (2012, str. 5), su pozitivan učinak precijenjene valute na „non-tradable“ sektor, konkretnije na one koji primaju plaće u tom sektoru, a troše uvozna dobra, i dobitci od oporezivanja sektora u naglom rastu („booming“). Najveći dobitnici su potrošači uvoznih dobara, koji se suočavaju sa oštrim padom cijena uvoznih dobara (u odnosu na cijene na domaćem tržištu) kao rezultatom aprecijacije.

Do nizozemske bolesti neće doći samo u slučaju porasta cijena dobara i usluga „booming“ sektora. Ostali načini pojave nizozemske bolesti, kako navodi Frankel (2010, str. 20), su ekspanzija na strani ponude koja vodi ka trgovinskom suficitu ostvarenom preko izvoza ili suficit kapitalnog računa ostvaren preko investicija uložениh u razvoj novog resursa. Pojam se, kako navodi, koristi i kod ostalih vrsta deviznih priljeva, kao što su inozemne doznake i pomoći. U svim slučajevima, rezultat je realna aprecijacija valute i okretanje „non-tradable“ sektoru (re-alokacija faktora proizvodnje). Realna aprecijacija valute je nominalna aprecijacija ako je tečaj fleksibilan, a ako je tečaj fiksiran dolazi do inflacije.

Republika Hrvatska više od svih ostalih članica Europske unije ovisi o turizmu, što dokazuje prihod od 17 % u ukupnom BDP-u. Bitno je istaknuti da je to najviši prihod u odnosu na sve ostale zemlje članice Europske unije, u kojima je prosjek 2,3 % (Marić, Samardžić i Protrka, 2017, str. 302).

Prema podacima sa DZS, u 2017. godini došla su 17,4 milijuna turista koji su ostvarili 86,2 milijuna noćenja u turističkim smještajnim objektima u Hrvatskoj. Navedeni podaci pokazuju kako je turizam od velike važnosti, odnosno da je Hrvatska zemlja koju se trenutno smatra jednom od najpopularnijih turističkih destinacija. Najviše noćenja turista u 2017. ostvarila je Istarska županija, i to 25 milijuna noćenja, što je 29% ukupno ostvarenih noćenja. Slijede noćenja ostvarena u Splitsko-dalmatinskoj županiji (19%), u Primorsko-goranskoj (17%), u Zadarskoj (11%), u Dubrovačko neretvanskoj (9%) i Šibensko-kninskoj županiji (6%), što je ukupno 91%. Ovi podaci navode na to kako je turizam značajna djelatnost u obalnim regijama, onima koje obiluju prirodnim resursima kao što su plaže, prirodna područja, sunčano vrijeme i slično. Iako turizam značajno doprinosi BDP-u ne mora značiti da je Hrvatska, radi priljeva deviza, došla ili će doći u situaciju u kojoj je „zaražena“ nizozemskom bolesti.

Analizirajući odnos realnog tečaja, prihoda od turizma i deindustrijalizacije Deskar Škrbić (2017) zaključuje kako se u Hrvatskoj ne javljaju simptomi nizozemske bolesti, ali ne isključuje mogućnost javljanja iste ukoliko se uzlet sektora turizma dalje nastavi.

Slično Hrvatskoj, turistički sektor daje velik doprinos ukupnom BDP-u i dobiva sve veću važnost i u Tajlandu, ali, prema istraživanju Kenell (2008, str. 3) nije došlo do nizozemske bolesti. Tajlandsku proizvodnju čini širok spektar izvoznih dobara, a industrija najviše pridonosi BDP-u i priljevu kapitala, tako da Tajland nije ovisan samo o turizmu kada se govori o priljevima stranog kapitala. Sve do sada navedeno, potiče na promišljanje o mjerama makroekonomske politike koje bi, ukoliko dođe do šoka, trebale spriječiti moguće negativne efekte.

1.1.2. Predmet istraživanja

Predmet istraživanja ovog rada odnosi se na postojanje ili nepostojanje „Dutch Disease“ u Republici Hrvatskoj. Kao bitne stavke, u radu će se istražiti takozvani „Spending Effect“ (dalje u tekstu SE) i „Resource Movement Effect“ (dalje u tekstu RME), koji se javljaju odnosno ne javljaju kao posljedica naglog rasta sektora turizma u Hrvatskoj. Sektor gospodarstva koji je u „boom-u“ (u ovom radu će se razmatrati turizam kao sektor u „boom-u“) povećava graničnu proizvodnost mobilnih čimbenika proizvodnje koji su u spomenutom sektoru uposleni i odvlači čimbenike iz drugih sektora. Ova promjena dovodi gospodarstvo u situaciju u kojoj se mora prilagoditi. Jedan od načina na koji će se gospodarstvo prilagoditi jest realni tečaj. Ovo Corden i Neary (1982, str.827) nazivaju RME. Nadalje, spomenuti autori navode, kada energetske koristi koristi relativno malo resursa koji se mogu privući iz ostalih sektora u gospodarstvu, taj učinak (RME) je zanemariv. Umjesto sintagme sa energetske koristi, u ovom radu će se koristiti sektor turizma. Dakle, kada se teze o RME i SE prilagode, i umjesto energetske koristi uvede sektor turizma (s obzirom da je to sektor hrvatskog gospodarstva koji je u naglom porastu), može se reći kako je RME zanemariv kada sektor turizma koristi relativno malo resursa koji se mogu privući iz ostalih sektora gospodarstva. Tada, umjesto učinka seljenja resursa, nagli rast sektora turizma utječe na pojavu SE. Viši realni dohodak, koji proizlazi iz sektora u uzletu, dovodi do povećane potrošnje usluga koja povećavaju njihovu cijenu (tj. dolazi do realne aprecijacije), što vodi do potrebe za daljnjim prilagodbama ekonomije. Ukoliko se u Hrvatskoj javlja SE trebala bi postojati negativna veza između rasta deviznog priljeva od turizma i realnog tečaja. Kada bi se pak u Hrvatskoj javljao RME, tada bi trebala postojati negativna veza između rasta deviznog priljeva od turizma i ekonomske aktivnosti u industriji.

1.2. Ciljevi, struktura i hipoteze istraživanja

1.2.1. Ciljevi istraživanja

Cilj ovog istraživanja razdvojiti će se na dva dijela, odnosno na teorijske i empirijske ciljeve.

U **teorijskom** pregledu, cilj ovog istraživanja je objasniti pojam „Dutch Disease“ (nizozemska bolest), dva glavna efekta tj. „Resource movement effect“ i „Spending effect“, koji su simptomi pojave nizozemske bolesti, kako se može neutralizirati, kojim mjerama makroekonomske politike spriječiti negativne efekte te kako se može mjeriti odnosno kako prepoznati je li zemlja „zaražena“ ovom bolesti.

U **empirijskom** dijelu rada, cilj je na temelju detaljnog uvida u podatke istražiti da li je nagli rast sektora turizma hrvatskog gospodarstva odvuкао resurse iz ostalih sektora i na taj način utjecao na smanjenu konkurentnost i deindustrijalizaciju. Dakle, donijeti će se zaključak o tome postoji li nizozemska bolest, uzrokovana naglim rastom sektora turizma, u Republici Hrvatskoj.

1.2.2. Struktura diplomskoga rada

Diplomski rad sastojat će se od **pet poglavlja**, kako slijedi.

U **prvom**, uvodnom poglavlju, obrazložiti će se problem i predmet istraživanja, ciljevi, struktura i hipoteze, metode i doprinos istraživanja.

U **drugom** poglavlju opisati će se pojam, simptomi i efekti „Dutch Disease“. Na kraju poglavlja će se iznijeti mjere makroekonomske politike kojima se nastoji smanjiti nastali šok.

Treće poglavlje biti će bazirano na dosadašnji doprinos empirijskih istraživanja o „Dutch Disease“ izazvane naglim rastom sektora turizma i na kretanje glavnih indikatora razvoja sektora turizma u Republici Hrvatskoj.

Pretposljednje, **četvrto** poglavlje, kao empirijski dio ovog rada, činiti će tri pod-poglavlja, koji se redom odnose na, (i) rast potražnje i priljeva deviza u turističkom sektoru i realnu aprecijaciju kune, (ii) direktnu deindustrijalizaciju i (iii) indirektnu deindustrijalizaciju. U ovom poglavlju će se na temelju statističke analize, regresijskom metodom, donijeti zaključak o prihvatanju ili odbacivanju hipoteza koje su postavljene u prvom poglavlju.

U **petom** poglavlju donijeti će se zaključna razmatranja na temelju teorijskog dijela rada i dobivenih rezultata iz empirijskog dijela rada. Na kraju slijedi popis literature, popis tablica i slika, te sažetak na hrvatskom i engleskom jeziku.

1.2.3. Istraživačke hipoteze

Na temelju problema i predmeta istraživanja postavljene su tri istraživačke hipoteze koje su navedene u nastavku.

H1: Rast potražnje i priljeva deviza u turističkom sektoru dovodi do realne aprecijacije kune („Spending Effect“)

Kako bi se analizom podataka pokazalo vodi li rast potražnje i priljeva deviza u turističkom sektoru do realne aprecijacije kune koristit će se linearna regresijska analiza. Analiza će se vršiti koristeći podatke o prihodima od turizma i podatke realnog efektivnog tečaja kune. HNB definira realni efektivni tečaj kao nominalni efektivni tečaj prilagođen za odnos cijena i/ili troškova između Hrvatske i njezinih glavnih trgovinskih partnera te je jedan od pokazatelja konkurentnosti domaćega gospodarstva. Regresijskom analizom će se donijeti zaključak te će se prihvatiti ili odbiti navedena hipoteza.

H2: Rast sektora turizma odvlači radnike iz ostalih sektora gospodarstva u sektor turizma („Resource Movement Effect“) – direktna deindustrijalizacija

Kako bi se analizom podataka pokazalo postoji li RME u Hrvatskoj (direktna deindustrijalizacija) koristit će se podaci o kretanju broja zaposlenih u „tradable“ i „non-tradable“ sektorima (prema NACE klasifikaciji) i podaci o prihodima od turizma. Linearnom regresijskom analizom će se donijeti zaključak o odnosu navedenih varijabli te će se prihvatiti ili odbiti navedena hipoteza.

H3: Realna aprecijacija kune i pritisci na rast plaća zbog rasta u sektoru usluga dovode do pada konkurentnosti „tradable“ sektora – indirektna deindustrijalizacija

Kako bi se analizom podataka pokazalo dolazi li do indirektne deindustrijalizacije u Hrvatskoj odnosno dovode li realna aprecijacija kune i pritisci na rast plaća zbog rasta u sektoru usluga do pada konkurentnosti „tradable“ sektora koristit će se podaci o realnom efektivnom tečaju, podaci o kretanju prosječne plaće po djelatnostima i o kretanju izvoza „tradable“ sektora. Linearnom regresijskom analizom će se donijeti zaključak o odnosu navedenih varijabli te će se prihvatiti ili odbiti navedena hipoteza.

1.3. Metode istraživanja

Metode istraživanja koje će se koristiti u ovome radu su induktivna, deduktivna, metoda analize, metoda sinteze, metoda deskripcije, metoda kompilacije i statistička metoda. **Induktivnom metodom**, koju definira Zelenika (2000, str. 323), će se na temelju pojedinačnih činjenica i saznanja, doći do uopćavanja i formiranja zakonitosti, odnosno spoznaje novih činjenica i novih zakonitosti. **Deduktivnom metodom**, koju definira Zelenika (2000, str. 323), će se iz općih stavova izvesti posebni, pojedinačni, i iz općih postavki doći do konkretnih pojedinačnih zaključaka, iz jedne ili više tvrdnji izvesti se neka nova tvrdnja koja proizlazi iz prethodnih tvrdnji. **Metoda analize** je „postupak znanstvenog istraživanja i objašnjenja stvarnosti putem raščlanjivanja složenih misaonih tvorevina (pojmova, sudova i zaključaka) na njihove jednostavnije sastavne dijelove i elemente i izučavanje svakog dijela (i elementa) za sebe i u odnosu na druge dijelove, odnosno cjeline.“ (Zelenika, 2000, str. 327). **Metoda sinteze** istražuje i objašnjava stvarnost putem „spajanja, sastavljanja jednostavnih misaonih tvorevina u složene i složenijih u još složenije, povezujući izdvojene elemente, pojave, procese i odnose u jedinstvenu cjelinu u kojoj su njezini dijelovi uzajamno povezani.“ (Zelenika, 2000, str. 329-330). **Metode deskripcije i kompilacije** biti će korištene kako u teorijskom tako i u empirijskom dijelu rada jer će se opisivati veze između pojava (npr. veza između rasta potražnje te priljeva deviza u turizmu i realne aprecijacije valute), a opisivati će se na temelju dosadašnjih istraživanja i na temelju rezultata dobivenih u empirijskom dijelu rada. **Statistička metoda** čija je spoznajna uloga osim opisivanja i objašnjavanje uzročno-posljedičnih odnosa tretiranih pojava (Zelenika, 2000, str. 341-344) koristiti će se u empirijskom dijelu rada. Vremenski obuhvat istraživanja odnosi se na razdoblje od 2002. (euro je 2002. godine uveden kao fizičko sredstvo plaćanja) do 2016. godine.

1.4. Doprinos istraživanja

Iako je, prvenstveno, pojam nizozemske bolesti kroz brojnu literaturu istražen, ono što nedostaje jesu istraživanja nizozemske bolesti koja je rezultat naglog rasta sektora turizma. Pa tako u svom radu Capó, Riera Font i Rosselló Nadal (2007, str. 615) navode kako nijedna literatura do tada nije bila fokusirana na turizam kao izvor povećanog blagostanja (kroz eksploataciju prirodnih resursa poput plaža, prirodnih površina i slično) radi modela razvoja temeljena na masovnom turizmu. Osim slabog doprinosa literature na temu nizozemske bolesti uzrokovane naglim rastom turizma, ono što nedostaje jesu istraživanja o Republici Hrvatskoj. Kao što je već u radu navedeno, zadnjih godina sektor turizma značajno raste za razliku od ostalih sektora i tako zauzima sve veći udio u BDP-u Hrvatske. Kao ključni

sektor gospodarstva trebao bi biti zaštićen od potencijalnih slabosti, kao što je nizozemska bolest. Zato će ovo istraživanje u vidu zaključka o tome postoji li ili ne postoji nizozemska bolest u Hrvatskoj i u vidu mjera za ublažavanje negativnih efekata ove pojave doprinijeti količini relativno novog korpusa literature.

2. „DUTCH DISEASE“

2.1. Pojam „Dutch Disease“

Pojam Nizozemske bolesti, kako ističe Corden (1984, str. 359), se po prvi puta koristi u „The Economist-u“ 1977. godine kako bi opisao oštar rast blagostanja u Nizozemskoj za vrijeme 1960-ih uzrokovan otkrićem velikih rezervi plina. Nakon otkrića, došlo je do negativnih učinaka na nizozemsku proizvodnju, uglavnom kroz naknadnu aprecijaciju realnog deviznog tečaja. Naime, kako su rasli prihodi od izvoza, tada rastućeg sektora, došlo je do aprecijacije nizozemskog guldena što je imalo negativan efekt na ostale industrije.

Dakle, nizozemska bolest bila bi stanje u kojem postoji izvozna oslonjenost na samo jedan proizvod pa dolazi do povećanja potražnje za domaćom valutom kojom se taj proizvod plaća te posljedično, do njene aprecijacije, što dovodi do poskupljenja svih domaćih proizvoda na međunarodnom tržištu te u konačnici, do pada konkurentnosti i stagnacije ostalih gospodarskih sektora (Jošić i Maček Pandak, 2017, str. 126). U slučaju Hrvatske, pod pretpostavkom da postoji nizozemska bolest uzrokovana naglim rastom sektora turizma, to bi značilo povećanu potražnju za hrvatskom kunom jer njome turisti plaćaju primjerice uslugu smještaja. Turisti dakle dolaze u zemlju, mijenjaju svoje valute za domaću valutu odnosno kunu i plaćaju usluge turističkog sektora što uzrokuje aprecijaciju kune i poskupljuje hrvatske proizvode na međunarodnom tržištu.

Bresser-Pereira (2008) navodi dvije moguće vrste nizozemske bolesti: ona koja je uvijek postojala i spriječila industrijalizaciju, kao što je to slučaj sa zemljama koje proizvode naftu; i nizozemsku bolest zemlje koja je neko vrijeme uspjela neutralizirati bolest i razvijati se, ali nakon određenog vremena u ime radikalnog liberalizma uklonila mehanizme neutralizacije i počela rasti po vrlo niskim stopama, kao što je to slučaj s latinoameričkim zemljama koje su prošle liberalizacijske reforme bez zamjene starog sustava subvencija racionalnijim sustavom poreza na prodaju robe koja je izazvala bolest.

Još jedna definicija nizozemske bolesti, i to ona Svjetske banke (2010), glasi da je ona fenomen koji odražava promjene u strukturi proizvodnje koje su uzrokovane šokom poput velikog otkrića prirodnog resursa, povećanja međunarodnih cijena izvoznog dobra ili prisutnosti trajnih inozemnih doznaka ili priljeva kapitala. Objašnjenje kako su povezani navedeni šokovi, odnosno što im je zajedničko da bi uzrokovali nizozemsku bolest, slijedi u nastavku. Otkriće prirodnog resursa, na koji se ekonomija oslanja, povećanje međunarodnih cijena izvoznog dobra, prisutnost trajnih inozemnih doznaka ili trajnog priljeva kapitala

očitava se kroz priljev deviza veći nego što je bio prije prethodno navedenih šokova. Veći priljev deviza, posljedično znači i veću potražnju za domaćom valutom pa tako i njenu aprecijaciju odnosno jačanje.

U „core“ modelu o kojem piše Corden (1984, str. 360) postoje tri sektora i to redom „booming“ (u nastavku B) sektor odnosno rastući, „lagging“ (u nastavku L) sektor odnosno opadajući i „non-tradable“ (u nastavku N) sektor odnosno sektor međunarodno ne-razmjenjivih dobara. Prva dva sektora proizvode razmjenjiva dobra tj. „tradable“ dobra i suočavaju se sa međunarodno zadanim cijenama. Output u pojedinom sektoru je proizveden faktorom proizvodnje specifičnim za taj sektor. Radna snaga se slobodno kreće među trima sektorima dok se naknade za rad ne izjednače. Cijene svih proizvodnih faktora su fleksibilne i svi faktori proizvodnje su mobilni. Nagli rast B sektora ima inicijalni efekt povećanja agregatnih prihoda od faktora uposlenih u tom sektoru. Nagli rast se događa na jedan od tri načina. Prvi je kada dođe do egzogenog tehničkog poboljšanja u B, što miče proizvodnu krivulju na povoljniji položaj, ali ovo poboljšanje je ograničeno samo na dotičnu zemlju. Drugi je kada dođe do otkrića novih resursa (ili povećanja ponude nekog faktora proizvodnje), i treći kada B sektor proizvodi samo za izvoz, bez plasiranja na domaće tržište i dođe do egzogenog rasta cijene izvoznog proizvoda na svjetskom tržištu u odnosu na cijene uvoznih dobara.


Do nizozemske bolesti neće doći samo u slučaju porasta cijena dobara i usluga „booming“ sektora. Ostali načini pojave nizozemske bolesti, kako navodi Frankel (2010, str. 20), su ekspanzija na strani ponude koja vodi ka trgovinskom suficitu ostvarenom preko izvoza ili suficit kapitalnog računa ostvaren preko investicija uložених u razvoj novog resursa. Pojam se, kako navodi, koristi i kod ostalih vrsta deviznih priljeva, kao što su inozemne doznake i pomoći. U svim slučajevima, rezultat je realna aprecijacija valute i okretanje „non-tradable“ sektoru (re-alokacija faktora proizvodnje). Realna aprecijacija valute je nominalna aprecijacija ako je tečaj fleksibilan, a ako je tečaj fiksiran dolazi do inflacije.

2.2. Simptomi „Dutch Disease“

Bresser-Pereira (2008, str. 60), prema Oomes i Kalcheva, (2007), navodi najvažnije simptome nizozemske bolesti: precijenjenost valute, niske stope rasta proizvodne industrije, umjetno visoke realne plaće i visoka nezaposlenost.

Simptomi nizozemske bolesti u nekoj zemlji su trajni kada ta zemlja nikada nije proizvodila industrijska dobra, ili su posljedica neke nove činjenice koja je već industrijaliziranu zemlju

zaustavila da neutralizira bolest, ili radi promjene uvjeta razmjene koji povećavaju tržišnu cijenu robe. U posljednja dva slučaja doći će do realne aprecijacije domaće valute bez smanjenja trgovinskog suficita, deindustrijalizacije i industrijska poduzeća koja su izvozno orijentirana će povećati uvoznu komponentu u svrhu svoje proizvodnje (Bresser-Pereira, 2008). Na **Slici 1** prikazano je kretanje indeksa fizičkog obujma industrijske proizvodnje Hrvatske za razdoblje od 2011. do 2017. godine. Hrvatska se skladno kretanju navedene pojave ne može smatrati kao zemlja koja nikada nije proizvodila industrijska dobra. U posljednjoj godini prikazanoj na **Slici 1**, 2017., bilježi rast u odnosu na 2015. godinu. Uz pretpostavku da postoji nizozemska bolest u Hrvatskoj, njeni simptomi neće biti trajni jer se ne može reći da Hrvatska nikada nije proizvodila industrijska dobra.



Slika 1: Indeksi fizičkog obujma industrijske proizvodnje za industriju ukupno u razdoblju od 2011. do 2017. godine (2015.=100)

Izvor: Izrada autora prema podacima sa stranice Državnog zavoda za statistiku,
https://www.dzs.hr/Hrv_Eng/Pokazatelji/MSI%20INDUSTRIJA.xlsx

Jedno od istraživanja deindustrijalizacije u Hrvatskoj, točnije ono Penave i Družića (2015, str. 851) govori o tome kako je u razvijenim zemljama rast produktivnosti, investicija i međunarodne trgovine imao važnu ulogu, dok to nije bio slučaj u Hrvatskoj. Investicije nisu imale očekivani učinak, a ni međunarodna trgovina u modelu deindustrijalizacije nije bila statistički značajna varijabla. U modelu je dummy varijabla socijalizam bila značajna. Prema navedenim autorima, deindustrijalizacija se dogodila neposredno nakon neovisnosti Hrvatske i kako postoje velike strukturne razlike između Hrvatske i razvijenih ekonomija.


Dakle, glavni simptomi nizozemske bolesti su precijenjena valuta odnosno realna aprecijacija domaće valute koja će voditi padu konkurentnosti, niskim stopama rasta proizvodne industrije, umjetno visokim realnim plaćama i visokoj nezaposlenosti.

2.3. Efekti „Dutch Disease“

Corden i Neary (1982.) govore o dva efekta nizozemske bolesti i to efektu potrošnje (SE) i efektu seljenja resursa (RME). SE se javlja kada povećanje prihoda radi „booming“ sektora dovede do rasta agregatne potražnje i potrošnje privatnog i javnog sektora. Povećanje u potražnji za „non-tradable“ dobrima vodi povećanju cijena i output-a u sektoru „non-tradable“ dobara. Plaće će imati tendenciju rasta i istiskivati će profit iz sektora razmjenjivih dobara (industrijska proizvodnja) u kojem su cijene fiksne i međunarodno zadane. RME se javlja kada sektor u uzletu privlači kapital i rad iz ostalih sektora gospodarstva. Točnije, smanjeni output u „non-tradable“ sektoru utječe na to da cijene „non-tradable“ dobara rastu u odnosu na cijene „tradable“ dobara koje su fiksne i međunarodno zadane.

Prvi efekt koji se javlja je SE. Kada je jedan dio dodatnog dohotka B sektora potrošen, bilo direktno od strane vlasnika faktora proizvodnje ili indirektno kroz prikupljene poreze i zatim potrošeno od strane države, i pod uvjetom da je dohodovna elastičnost potražnje N sektora pozitivna, cijene N sektora će u odnosu na cijene L sektora rasti. Ovo je realna aprecijacija. Odvući će se resursi u B iz L i N, i doći će do pomicanja krivulje potražnje. Na **Slici 2** okomita os odnosi se na cijene (P), točnije cijene N u odnosu na L. Krivulja ponude je izvedena iz krivulje transformacije između „tradable“ i „non-tradable“ sektora. Krivulja potražnje pokazuje količinu potražnje za N po različitim cijenama kada je potrošnja uvijek jednaka dohotku. SE je pomakao krivulju potražnje od D_0 do D_1 i povećao P_n odvlačeći resurse iz L sektora u N sektor. Granična proizvodnost rada raste u B kao rezultat naglog rasta tako da, ako su nadnice konstantne u smislu „tradable“ sektora, potražnja za radom u B raste, i potiče kretanje rada iz L i iz N sektora. Ovaj efekt ima dva dijela. Kretanje radne snage iz L u B smanjuje proizvodnju L sektora. Ovo se zove direktna deindustrijalizacija zato što ne uključuje tržište N dobara i ne uključuje aprecijaciju realnog tečaja. Kada postoji kretanje radne snage iz N u B i realni tečaj je konstantan, RME pomiče krivulju ponude sa S_0 na S_1 i stvara manjak ponude N dobara. Uz ono što izaziva SE dolazi i do naknadne realne aprecijacije. Stoga, dolazi i do naknadnog kretanja radne snage iz L u N što pojačava deindustrijalizaciju prvotno rezultiranu SE. Kombinirajući dva efekta, dolazi do kretanja radne snage iz L u N i onog što se naziva indirektna deindustrijalizacija, koja nadopunjuje

prvotno navedenu direktnu deindustrijalizaciju koja je rezultat seljenja rada iz L u B. Kao što je vidljivo na **Slici 2**, output N sektora može biti u konačnici viši ili niži nego na početku. SE ga obično povećava, a RME ga čini nižim (Corden, 1984, str. 360 i 361).



Slika 2: „Dutch disease“

Izvor: Corden, 1984, str. 361

O efektima nizozemske bolesti se u kontekstu Republike Hrvatske može raspravljati u dva slučaja. Prvi je kada se govori o nizozemskoj bolesti izazvanoj naglom ekspanzijom građevine, a drugi kada se govori o nizozemskoj bolesti izazvanoj naglim rastom turizma.

U razdoblju prije krize Hrvatska je zabilježila snažan rast cijena nekretnina popraćen ekspanzijom djelatnosti građevinarstva i poslovanja nekretninama, ali što je usporedno pridonosilo zanemarivanju tehnološkog razvoja, investicija, zapošljavanja i stvaranja dodane vrijednosti u proizvodno-izvoznim djelatnostima s većom dodanom vrijednošću, odnosno predstavljao je jedan od faktora direktne i indirektna deindustrijalizacije zemlje. Dok su u isto vrijeme druge tranzicijske zemlje povećavale investicije i efikasnost u prerađivačkoj industriji (posebice Rumunjska, Češka, Mađarska i Slovačka), Hrvatska je dvostruko pa i trostruko više od ostalih povećavala investicije u građevinarstvu. Iako Hrvatska nije dio euro područja, inozemno zaduživanje kao izvor financiranja ekspanzije sektora nekretnina bilo je u pod značajnim utjecajem monetarne prakse ECB-a i politike jeftinog eura kojem su pridonosili

niski kamatnjaci u euro području do 2006. Kao rezultat obilnog priljeva stranog kapitala, veće količine novca u optjecaju, nižih kamatnjaka te rasta domaće potražnje, stvarali su se učinci na rast cijena u svim drugim domaćim sektorima (posebno u sektoru međunarodno nerazmjenjivih dobara i javnom sektoru), što je omogućilo rast prosječnih plaća (povećalo jedinične troškove rada) i uz učinke realne aprecijacije kune dodatno smanjivalo konkurentnost izvoza i mogućnosti ekspanzije u drugim djelatnostima. Sve navedeno djelovalo je kako na sektorske migracije investicija i dohotka, tako i promjene u potražnji za radnom snagom, što je predstavljalo faktore pozitivnih promjena u pred-kriznom razdoblju, ali danas u razdoblju niskih cijena nekretnina i problema građevinskog sektora predstavlja jedan od faktora visoke nezaposlenosti (posebice niskokvalificiranih osoba) i razlog je snažnog pada ukupnih investicija i potrošnje na makro razini (Ivanov, 2015, str. 4).

2.4. Mjere makroekonomske politike za uklanjanje negativnih efekata „Dutch Disease“

Nakon što su jasniji simptomi i efekti nizozemske bolesti potrebno je promišljati o mjerama makroekonomske politike koje će ukloniti moguće negativne efekte, odnosno, postavlja se pitanje što bi nositelji politike trebali učiniti?

Mjere makroekonomske politike tako će ovisiti o tome je li novonastalo bogatstvo (od otkrića novog resursa) privremeno ili trajno. Tako u svom radu Ebrahimzadeh (2017) ističe mjere makroekonomske politike za prethodno navedena dva slučaja. U zemljama koje očekuju da će novootkriveni resurs biti poprilično brzo iscrpljen, mjera koja je privremena jesu potpore. Postojeći uvjeti trgovine također u spomenutom slučaju mogu biti samo privremeni. Političari se mogu okrenuti zaštiti ranjivih sektora preko deviznih intervencija. Spomenuto bi značilo prodaju domaće valute u zamjenu za devize odnosno povećanje deviznih rezervi. Ovom mjerom kontrolirala bi se vrijednost domaće valute i gospodarstvo bi se izoliralo od kratkoročnih poremećaja uzrokovanih nizozemskom bolesti. Ono što ostaje izazov jest osigurati da povećanje rezervi ne dovede do inflacije i da se dodatno bogatstvo zemlje troši mudro i vodi se transparentno kroz, na primjer, račun centralne banke ili fonda za novootkriveni resurs (npr. posebni fond za naftu). Sa druge strane, u zemljama koje očekuju da će novootkriveni resurs biti trajan, političari će se susresti sa neizbježnim strukturnim promjenama u gospodarstvu kako bi se osigurala ekonomska stabilnost. Mjere za povećanje produktivnosti „non-tradable“ sektora mogu biti privatizacija, restrukturiranje i ulaganje u prekvalifikaciju radnika. Također, još jedna moguća mjera je i diversifikacija izvoza kako bi se smanjila ovisnost o rastućem sektoru te kako bi se nacionalna ekonomija zaštitila od vanjskih šokova poput naglog pada cijena roba.

Valja naglasiti da izvor problema nizozemske bolesti u turističkim gospodarstvima nije obilje prirodnih resursa ili specijalizacija. To je neuspjeh nositelja ekonomske politike da posvete dovoljno pažnje odrednicama dugoročnog gospodarskog rasta. Regije ili zemlje čiji sektor turizma prolazi kroz proces brzog rasta moraju točno procijeniti dugoročne posljedice specijalizacije u turizmu i nizozemske bolesti. Potreba za uravnoteženim gospodarstvom, za integracijom poljoprivrede s turizmom (kroz marketing, korištenje lokalnih proizvoda, farme turizma, itd.) i potreba za privlačenjem novih tvrtki, posebno onih vezanih uz nove tehnologije u turističkim područjima, dio su održivog razvoja turizma (Capó, et al., 2007, str. 625).

Naspram ovom istraživanju koje govori o neuspjehu nositelja ekonomske politike po pitanju nizozemske bolesti, sljedeće navedeno govori o utjecaju otkrića prirodnog resursa na ekonomski rast odnosno kako kvaliteta institucija uvjetuje politiku u situaciji „boom-a“.

Naime, ne postoje statistički značajni dokazi koji upućuju na to da prirodni resursi direktno pogoršavaju upravljanje državom ili kvalitetu institucija, iako ima dokaza da kvaliteta postojećih institucija uvjetuje kvalitetu ekonomske politike koju zemlje koriste u situacijama kada se javlja veliko otkriće prirodnog resursa tj. kako prirodni resursi utječu na rast. (Svjetska banka, 2010 prema Collier i Goderis, 2007).

2.4.1. Monetarna i tečajna politika

U zemljama koje su izvoznice roba, ono što je bitno za makroekonomsko upravljanje jest odabir primjerene monetarne politike. Na primjer, ciljanje inflacije se pokazalo kao iznimno uspješan instrument monetarne politike, iako može doći do aprecijacijskih pritisaka kada cijena izvoznog dobra raste. Raspravljano je o razvoju prikladnijeg oblika ciljanja za zemlje izvoznice. Navedena vrsta politike je djelovala u mnogim zemljama, a manje je bila uspješna u stabiliziranju odnosa cijena razmjenjivih i ne-razmjenjivih dobara u zemljama izvoznicama (Svjetska banka, 2010, str. 6). Zemlje izvoznice mogu odabrati specifičnije ciljanje, odnosno ciljanje posebnog indeksa potrošačkih cijena koji ima veći udio cijena izvoznih dobara i/ili proizvodnih cijena tj. „Export Price Index“ i „Producer Price Index“ (Svjetska banka, 2010, str. 6, prema Frankel, 2009). Ovaj način ciljanja se čini više prikladan za zemlje koje pokazuju simptome nizozemske bolesti, ali je složeniji za provođenje.

S obzirom da je glavni cilj središnje banke Hrvatske, koja je zadužena za monetarnu politiku, održavanje stabilnosti cijena i niske i stabilne inflacije, ukoliko empirijski dio rada pokaže da Hrvatska ima simptome nizozemske bolesti, nositelji monetarne politike trebali bi promišljati o prethodno pojašnjenom specifičnijem ciljanju.

Hrvatska narodna banka vodi politiku upravljanoga fluktuirajućeg tečaja. To je tečajni režim u kojemu, s jedne strane, domaća valuta nije fiksno vezana uz neku drugu stranu valutu ili košaricu valuta, već odražava kretanja na deviznom tržištu, te s druge strane nominalni tečaj kune prema euru stabilan je zbog povremenih HNB-ovih deviznih intervencija. Kretanja na deviznom tržištu ovise o novčanim tokovima s inozemstvom uključujući, primjerice, plaćanja uvoza i naplate izvoza, priljeve deviza zbog zaduživanja u inozemstvu ili otplate inozemnog duga, te priljeve na osnovi fondova EU-a. Tečaj kune prema euru pritom se slobodno formira na deviznom tržištu ovisno o kretanjima ponude deviza i potražnje za devizama. HNB se povremeno uključuje na devizno tržište, i to kada ocijeni da je već prisutno ili je moguće prenaplašeno kolebanje tečaja. HNB ne utvrđuje unaprijed gornju i donju granicu kretanja tečaja kune prema euru koju se obvezuje braniti (gornju i donju intervencijsku točku). Za razliku od tečaja HRK/EUR, Hrvatska narodna banka ne može utjecati na vrijednost kune prema drugim stranim valutama (američkom dolaru, funti sterlinga, švicarskom franku itd.) jer je njihova vrijednost određena odnosima eura i tih valuta na svjetskim deviznim tržištima (HNB, 2015.).

2.4.2. Fiskalna politika

Nositeljima ekonomske politike, fiskalna politika jest glavni instrument za rješavanje negativnih utjecaja nizozemske bolesti iz slijedećih razloga: alat je koji povećanje blagostanja može učiniti permanentnim, može ograničiti SE (glavni transmisijski kanal prijenosa negativnih utjecaja u zemljama sa niskim dohotkom), i može izgladiti troškove kako bi se smanjila njihova volatilnost. Naime, postoje empirijski dokazi o tome da državna potrošnja korelira sa povećanjima prihoda od resursa (Svjetska banka, 2010, str. 5). Kada bi se govorilo o Hrvatskoj, državna bi potrošnja korelirala sa prihodima od turizma, ali detaljnije analize o navedenom odnosu neće biti obuhvaćene u okviru rada.

Kako bi se ograničila povećana državna potrošnja uzrokovana povećanjem prihoda od turizma ili nekog drugog prihoda koji je ostvaren na temelju „boom-a“ potrebno je osnovati posebni fond koji će služiti za ublažavanje negativnih efekata.

Poseban rezervni fond i fiskalni suficit su makroekonomske mjere koje mogu ublažiti ili posve otkloniti potencijalne probleme povezane s nizozemskom bolešću u slučaju Hrvatske (Deskar Škrbić, 2017).

2.4.3. Politika potrošnje i strukturna politika

Politika potrošnje također može pomoći u zaustavljanju nizozemske bolesti. Usmjeravanje potrošnje prema „tradable“ sektoru (uključujući uvoz) više nego prema „non-tradable“ sektoru će pomoći na način da će usporiti SE. To se može ostvariti kroz poboljšanje kvalitete potrošnje kako bi se osiguralo da produktivnost raste u „non-tradable“ sektoru. Strukturna politika je također u tom slučaju bitna. Ako SE djeluje i kroz privatnu potrošnju, a ne samo državnu, politike poboljšavanja produktivnosti privatnih poduzeća će smanjiti utjecaj navedenog SE.

Politike koje utječu na rast potražnje za uvoznim dobrima, poput trgovinske liberalizacije, pomoći će smanjiti pritisak potražnje u „non-tradable“ sektoru i mogu biti način odgovora strukturne politike na nizozemsku bolest. Ukoliko bi se zemlja i dalje suočavala sa štetnim učincima uzrokovanim povećanjem prihoda od prirodnog resursa dolazi do potrebe za usmjeravanjem potrošnje posebno na investicije koje pomažu povećanju produktivnosti u sektoru ne-razmjenjivih dobara. Neka moguća rješenja su investicije u prometnu i logističku infrastrukturu, proširenje investicija u obrazovanje i pomoć pri savladavanju vještina korištenja nove tehnologije i inovacija, i slično (Svjetska banka, 2010, str. 5).

3. TEORIJSKI PREGLED ISTRAŽIVANJA O „DUTCH DISEASE“ IZAZVANE NAGLIM RASTOM SEKTORA TURIZMA

S obzirom na to da je prvotni model nizozemske bolesti bio koncipiran na temelju robnog izvoza, odnosno, u tom slučaju eksploataciji plina, potrebno je povezati i/ili razlikovati prvotni model od onog koji uključuje turizam kao način „izvoza“.

Copeland (1991) definira tri glavne razlike između turizma i robnog izvoza. Prva je da se potrošači kreću umjesto proizvoda. S obzirom da turisti konzumiraju dobra koja su uobičajeno ne-razmjenjiva, kao što su smještaj ili hrana u restoranima, ta dobra postaju razmjenjiva u smislu da stvaraju potrebu za razmjenom deviza. Druga je činjenica da turisti troše više od jednog dobra i posljednja je ta da turisti konzumiraju ove proizvode zajedno sa uslugama koje nemaju cijenu kao što su klima, priroda i krajolik.

Turistički sektor velik je doprinos ukupnom BDP-u i dobiva sve veću važnost u Tajlandu, ali nije došlo do pojave nizozemske bolesti. Tajlandsku proizvodnu industriju karakterizira širok raspon izvoznih dobara, a industrija je sektor koji najviše doprinosi BDP-u i priljevu stranog kapitala. Dakle, Tajland nije isključivo ovisan o turizmu niti je međunarodna konkurentnost Tajlanda smanjena kako teorija o nizozemskoj bolesti predviđa (Kenell, 2008).

Jedno od istraživanja nizozemske bolesti uzrokovane naglim rastom sektora turizma promatra sedam malih otočnih zemalja u razvoju, takozvanih SIDS zemalja („Small Island Developing States“). SIDS zemlje suočene su sa mnogim izazovima gospodarskog razvoja. Turizam se čini održivim, a ponekad i jedinim sredstvom za ostvarivanje gospodarskog rasta. Istraživanje Pratt-a (2015, str. 148) uspoređuje ekonomski utjecaj turizma na sedam SIDS zemalja. U istraživanju je korištena input-output analiza, „linkage“ analiza i CGE model za procjenu makroekonomskih i sektorskih utjecaja povećanog turizma na tim otočnim zemljama. Rezultati pokazuju da je sektor prometa ključni sektor u vidu multipliciranja dohotka. Multiplikatori dohotka od turizma pokazuju da turizam generira veliku količinu gospodarske aktivnosti, ali prihodi koji ostaju u odredištima su često vrlo mali. Rezultati pokazuju i da iskorištavanje ekonomije razmjera može biti način za maksimiziranje prednosti od turizma.

Uz potencijalne negativne efekte nizozemske bolesti, dolazi i još jedan, kojeg istraživači tematike nizozemske bolesti ne ističu uvijek. Naime, nagli rast turizma može dovesti do smanjenja blagostanja, kada turistički proizvodi intenzivno koriste obalno zemljište, i na taj

način negativno utječu na lokalnu zajednicu u vidu nemogućnosti njihova širenja (Nowak i Sahli, 2007, str. 49).

Nizozemska bolest je korisna, odnosno štetna, na blagostanje domaćeg stanovništva ako je sektor turizma kapitalno intenzivan, odnosno radno intenzivan (Chen, Lai i Chu, 2016). Nagli rast turizma uzrokuje da se rad i kapital sele od sektora „tradable“ dobara prema turističkom sektoru. Dvo-sektorski model, u kojem su potrebni rad i kapital kao inputi za proizvodnju „tradable“ i „non-tradable“ dobara, i mogu se slobodno kretati između navedenih sektora, pokazuje da, ako je sektor turističkih dobara radno intenzivan, nagli rast turističkog sektora će smanjiti blagostanje. U suprotnom, ako je sektor turizma kapitalno intenzivan, nagli rast sektora turizma povećava blagostanje jer stimulira akumulaciju kapitala (akumulira se više kapitala u odnosu na rad), odnosno povećava razinu kapitala u zemlji.

Slijedeći primjer nizozemske bolesti izazvane naglim rastom turizma jesu Balearsko i Kanarsko otočje kao dvije španjolske regije koje su visoko specijalizirane turističke ekonomije. Nagli rast sektora turizma koji se dogodio početkom 60-ih godina doveo je do znatnog povećanja u bogatstvu, zahvaljujući novoj rekreacijskoj uporabi prirodnih obalnih resursa. Tijekom godina ovo je dovelo do većeg usredotočenja na turizam i ne-razmjenjiva dobra (usluge i građevina), sa minimalnim usredotočenjem na industriju i poljoprivredu. Iako je dohodak stanovništva znatno porastao kao rezultat ove promjene u proizvodnji, postoje neke sumnje glede održavanja tih stopa rasta u dugoročnom razdoblju, ne samo zbog iscrpljenosti prirodnih resursa nego i zbog toga što je specijalizacija u turizmu sa sobom donijela nisku razinu obrazovanja, inovativnosti i tehnološkog napretka (Capó, et al., 2007, str. 625).

Nizozemska bolest se nije pojavila samo u prethodno navedene dvije regije već i u cijeloj Španjolskoj. Naime, Španjolska je od 2008. godine bila u značajnoj ekonomskoj recesiji. Turizam se, u toj situaciji, činio kao moguće rješenje za oslabljenu potražnju domaćeg gospodarstva i kao prilika za revitalizaciju ekonomije. Ipak, turizam ostavlja i duboke posljedice na gospodarstvo, na mikroekonomskoj razini, glede alokacije resursa, aprecijacije tečaja i potražnje za „non-tradable“ dobrima, koje mogu potaknuti nizozemsku bolest. Razvojem „recursive-dynamic CGE model-a“ (omogućuje analizu veze između sektora gospodarstva i njihovog utjecaja na gospodarski rast u vremenu), Inchausti-Sintes (2015, str. 172) procjenjuje mogućnost pojave navedenih posljedica. Turizam pozitivno utječe na rast ekonomije, ali nizozemska bolest djeluje na sektorskoj razini i uzrokuje seljenje resursa

prema „non-tradable“ sektoru što može ugorziti produktivnost, aprecirati realni efektivni tečaj i utjecati na gospodarski rast u dugom roku. Dokazano je kako turizam potiče aprecijaciju realnog tečaja što je u Španjolskoj potkopavalo tradicionalne sektore poput poljoprivrede, rudarstva i industrije kao jasna posljedica nizozemske bolesti (Inchausti-Sintes, 2015, str. 186).

Iako je Španjolska izlaz iz recesije tražila u turizmu kao prilici za revitaliziranje ekonomije, postoji istraživanje koje govori o nepostojanju pozitivnog učinka turizma na gospodarski rast. Analizom su obuhvaćene 133 zemlje za razdoblje od 1995. do 2007. godine, uključujući 32 zemlje koje su značajno ovisne o turizmu tijekom navedenog razdoblja. Rezultati su pokazali da specijalizacija u turizmu sama po sebi nije imala značajan utjecaj na gospodarski rast. Nadalje, zemlje koje su ujedno ovisne i o trgovini i o turizmu obično imaju znatno niži rast. Rezultati navedenog istraživanja su konzistentni sa sektorom turizma koji stvara efekte analogne nizozemskoj bolesti (Ghalia i Fidrmuc, 2015, str. 1).

Koristeći „cross-country“ analizu Holzner (2011, str. 929) pokazuje da zemlje sa većim udjelom prihoda od turizma u BDP-u rastu brže od ostalih. Zemlje sa većim dohotkom od turizma imaju tendenciju, ne samo ostvarivati veće stope gospodarskog rasta, nego i veće razine investicija i upisa u srednje škole (objašnjavajuće varijable modela su početna razina outputa, fizički i ljudski kapital). Zemlje ovisne o turizmu pokazale su se poprilično orijentirane prema vani, imajući niske razine promjene realnog tečaja. Turizam nije doveo ni do smanjenja industrijskog sektora. Analiza mogućih transmisijских kanala turizma na gospodarski rast pokazala je da se za većinu indirektnih učinaka turizma može očekivati djelovanje kroz kanale fizičkog i ljudskog kapitala. Glavna politika, koju navedeni autor predlaže za zemlje u razvoju sa potencijalom specijalizacije u turizmu, je investiranje izvan turizma, a u infrastrukturu, koja može biti korištena sa strane sektora turizma i sa strane industrije. Navedeno smanjuje troškove poslovanja i moguće distorzije realnog efektivnog tečaja. Dakle, produktivnija industrijska proizvodnja i manje produktivan sektor turizma mogu generirati iznadprosječni dohodak na temelju zajedničkog investiranja u fizičku infrastrukturu. Autor zaključuje kako, uz pomoć ove politike, neće doći do djelovanja nizozemske bolesti u zemljama koje ovise o turizmu.

S obzirom na temu rada, valja navesti i istraživanje Deskara Škrbića (2017) koji navodi kako je turistički bum doveo Hrvatsku u sam vrh EU prema kriteriju omjera inozemnih prihoda od turizma i BDP-a, ali se unatoč tome ne vidi negativna veza između rasta turističkog deviznog

prihoda i realnog tečaja te ekonomske aktivnosti u industriji, što bi inače bio simptom nizozemske bolesti.

Nasuprot navedenim primjerima, zanimljivo je spomenuti situaciju u Australiji, gdje je pojava nizozemske bolesti uzrokovana rastom izvoza minerala u Kinu i Azijske zemlje, a sektor koji je u zaostajanju je turizam. Naime, naglim rastom izvoza minerala australska valuta je narasla znatno naspram vodećih svjetskih valuta. Ovo je zadalo značajne probleme tradicionalnim izvoznim i uvoznim industrijama, jedna od kojih je turizam. Dokazan je negativan utjecaj rudarskog „boom-a“ na turizam, odnosno dokazano je postojanje nizozemske bolesti (Forsyth et. al, str. 1, 2014).

3.1. Negativan utjecaj volatilnosti valute i neravnotežnog tečaja na ekonomski rast

U istraživanju na 45 razvijenih i zemalja u razvoju u periodu od 1985. do 2015. godine Barguelli et al. (2018, str. 1323) dolaze do zaključka kako postoji negativan utjecaj volatilnosti nominalnog i realnog tečaja na gospodarski rast. Također, učinak volatilnosti tečaja ovisi o režimu tečaja i financijskoj otvorenosti, odnosno, volatilnost je više štetna kada zemlja usvoji fleksibilni tečajni režim i kada je financijski otvorena. Kada bi Hrvatska „bolovala“ od nizozemske bolesti, uzevši u obzir prethodno istraživanje, promjene razine tečaja, odnosno pad tečaja uzrokovan istom, utjecao bi na njen gospodarski rast.

Hrvatska narodna banka vodi politiku upravljanoga fluktuirajućeg tečaja, kao što je već prethodno u radu pojašnjeno. Ono što je važno istaknuti glede volatilnosti hrvatske valute jeste da se HNB, unatoč slobodnom formiranju tečaja kune prema euru, povremeno uključuje na devizno tržište, i to onda kada ocjeni da je kolebanje tečaja prenaplašeno. Ona, dakle, brani gornju i donju granicu kretanja tečaja kune prema euru. Ovakva politika narodne banke nastoji spriječiti preveliko kolebanje tečaja odnosno volatilnost valute. S obzirom na upravljanje fluktuirajućim tečajem, volatilnost bi tako bila više štetna za Hrvatsku.

Nadalje, u svom istraživanju Magud i Sosa (2010, str. 27) pokazuju kako kada realni tečaj aprecira, dolazi do preraspodjele faktora proizvodnje i industrijska proizvodnja pada. Dakle, realna aprecijacija tečaja sprječava gospodarski rast. Neusklađenost realnog tečaja i njegove ravnotežne vrijednosti također smanjuje rast. Precijenjene vrijednosti uvijek su negativne za gospodarski rast, dok dokazi o podcijenjenosti nisu uvjerljivi.

Sheng (2011, str. 1227) navodi tri kvantitativne hipoteze za rješavanje problema nizozemske bolesti:

1. Više poreza u sektoru turizma, kako bi se potaknuo rast ne-turističkih sektora, zemlju će dovesti u situaciju u kojoj će njena ekonomija brže rasti.
2. Više poreza u sektoru turizma, kako bi se potaknuo rast ne-turističkih sektora, zemlju će dovesti u situaciju u kojoj će njena ekonomija brže rasti, ali sa logaritamski manjim povećanjima.
3. Više subvencija za ne-turistički sektor, koristeći prihode od turizma, ne ubrzava ekonomski rast, ali pomaže izbjeći volatilnost navedenih prihoda od turizma.

3.1.1. Precijenjenost valute

Aprecijacija domaće valute može osim nizozemskom bolesti biti izazvana i nedosljednom ekonomskom politikom. Pa tako Magud i Sosa (2013) u svom radu navode da ako ekonomski agenti za privremeni šok očekuju da će biti trajan, doći će do „overshootinga“ i realni tečaj biti će precijenjen i na kraju neodrživ, naravno, ako se ne korigira. Ako ekonomska politika ide u smjeru da trajno izmijeni realni tečaj od njegove ravnotežne vrijednosti, pojaviti će se nedosljednosti. Vjerojatni učinci su da će „long-run pain“ biti veća od „short-run gain“. Tako da je priroda šoka, odnosno trajnost, važan faktor u odlučivanju je li potrebno ili nije brinuti o pojavi nizozemske bolesti. Ako je šok privremen, uloga ekonomske politike jest ublažiti njegov utjecaj kako bi se zaustavili simptomi nizozemske bolesti. Prethodno spomenuti autori također navode kako je u nekim slučajevima teško a priori odrediti je li šok privremen ili trajan.

3.2. „Spending Effect“

Prvi odnos koji treba istražiti kako bismo odgovorili na pitanje postoji li efekt potrošnje odnosno SE je onaj između prihoda od turizma i realnog efektivnog tečaja (REER), koji se temelji na ranije objašnjenom efektu potrošnje. Konkretnije, u nizozemsku bolest možemo sumnjati ako je rast turizma praćen realnom aprecijacijom tečaja (Deskari Škrbić, 2017).

Deskari Škrbić (2017) prema Bakić (2016) u svom radu ističe pojednostavljene i prilagođene efekte nizozemske bolesti izazvane naglim rastom sektora turizma:

1. rast potražnje i priljeva deviza u turističkom sektoru dovodi do realne aprecijacije kune (efekt potrošnje)

2. rast turizma odvlači radnike iz ostalih sektora u sektor turizma (direktna deindustrijalizacija)
3. realna aprecijacija i pritisci na plaće zbog rasta u sektoru usluga dovode do pada konkurentnosti sektora razmjenjivih dobara, što dovodi do indirektna deindustrijalizacije.

Prema tome, efekti „nizozemske bolesti“ izazvani turizmom u Hrvatskoj bi se trebali očitovati u aprecijaciji realnog tečaja koja dovodi do smanjenja izvoza, zaposlenosti i udjela sektora razmjenjivih dobara u ekonomiji.

Ipak, u mnogim zemljama su hoteli i ostala imovina čije usluge intenzivno konzumiraju turisti često u vlasništvu ne-rezidenata. To može imati značajan utjecaj na pozitivne efekte rasta turizma (Copeland, 1991, str. 518).


3.3. „Resource movement effect“

RME predstavlja situaciju u kojoj dolazi do seljenja proizvodnih faktora iz „tradable“ u „non-tradable“ sektor. U slučaju nizozemske bolesti izazvane naglim rastom sektora turizma može doći do pojave navedenog efekta koji će u nastavku biti pojašnjen. Nagli rast sektora turizma stvarat će sve veće prihode od turizma. Veći prihodi od turizma se očitavaju kroz priljev deviza i veću potražnju za domaćom valutom, odnosno kunom u slučaju Hrvatske. Domaća valuta jača, i plaće u „non-tradable“ sektoru (u koji spadaju turističke djelatnosti) rastu. Prethodno navedena situacija ima za posljedicu seljenje resursa proizvodnje odnosno RME. Radna snaga tako bi se trebala kretati iz „tradable“ sektora u „non-tradable“ sektor, što bi značilo u konačnici pad zaposlenih u prvom, i rast u drugom navedenom sektoru. Kako industrijska proizvodnja spada u „tradable“ sektor, tako bi padom zaposlenih u ovom sektoru trebalo doći do pada industrijske proizvodnje. Prije analize podataka, koja će biti prikazana u četvrtom dijelu rada i koja može dati uvid u postojanje efekta seljenja resursa izazvanog naglim rastom sektora turizma u Republici Hrvatskoj, potrebno je istaknuti nekoliko važnih činjenica vezanih uz deindustrijalizaciju.

Deskari Škrbić (2017) prema Rowthorn i Coutts (2013) ističe da je deindustrijalizacija globalni fenomen, koji se prvenstveno vezuje uz razvijene zemlje, a odražava relativno smanjenje broja zaposlenih u industriji. Faktori koji utječu na stupanj deindustrijalizacije su rast produktivnosti (isti output se može proizvesti s manjim brojem radnika) i promjene u obrascima potrošnje. Navodi kako se pad udjela poljoprivrednih proizvoda u potrošnji može

objasniti značajnim padom cijena industrijskih proizvoda (kao primjer pada cijena industrijskih proizvoda može se navesti pad cijena mobitela) te važnošću industrije u nekoj zemlji što je posljedica specijalizacije u međunarodnoj razmjeni (neke zemlje se specijaliziraju za izvoz proizvoda (Njemačka), a neke za izvoz usluga (UK)). Dakle, ako se radi o prirodnom procesu deindustrijalizacije, udjel industrije u gospodarstvu trebao bi se smanjivati, dok bi apsolutni iznosi proizvodnje i/ili zaposlenosti trebali nastaviti rasti, ali sporije od sektora usluga. Tek ako se radi o padu važnosti industrije u apsolutnim terminima, onda se govori o nepovoljnoj deindustrijalizaciji koja nije posljedica razvijenosti ekonomije nego je razvojna pogreška.

Deskari Škrbić (2017) prema Družić, Penava i Raguž (2012) ističe kako Hrvatska, za razliku od razvijenih europskih zemalja, nije prošla kroz prirodan tijek industrijalizacije od lake do teške industrije nego se ubrzana industrijalizacija u socijalističkom periodu temeljila na teškoj industriji, čime se stvorila neadekvatna i neučinkovita struktura industrije. Također, ne treba zaboraviti učinke rata u kojem su uništena brojna postrojenja, zatim pretvorbe i privatizacije koje su, uz brojne prednosti, u jednom dijelu dovele i do „rastakanja“ većeg broja industrijskih poduzeća, a dodatan šok došao je zbog gubitka glavnih „izvoznih“ tržišta nakon raspada Jugoslavije. Svi ovi faktori mogli su dovesti do značajnog pada važnosti industrije u hrvatskom gospodarstvu, a da nemaju nikakve veze s mehanizmima vezanim uz nizozemsku bolest.



Slika 3: Indeksi proizvodnje, zaposlenih i proizvodnosti rada u industriji od 2007. do 2016.

Izvor: DZS, Hrvatska u brojkama 2017, str. 6

Na **Slici 3** prikazani su indeksi proizvodnje, zaposlenih i proizvodnosti rada u industriji za razdoblje od 2007. do 2016. godine sa baznom 2010. godinom. Iz slike se vidi kako proizvodnost rada raste svaku godinu od 2010. pa nadalje. Broj zaposlenih pada kao i industrijska proizvodnja, ali broj zaposlenih više pada. Ovo se može objasniti povećanom proizvodnosti tj. potrebno je manje radnika za obavljanje istog posla.

3.4. Sektor turizma u Republici Hrvatskoj

Zašto je baš sektor turizma odabran kao potencijalni uzrok nizozemske bolesti bit će pojašnjeno u nastavku. Tablica 1 prikazuje glavne indikatore razvoja sektora turizma i njihovo kretanje za razdoblje od 1980. do 2015. godine. Glavni indikatori su redom:


1. broj kreveta u turističkom smještaju,
2. broj dolazaka turista,
3. broj noćenja,
4. prosječan broj noćenja po krevetu i
5. prosječan broj noćenja po dolasku turista.

Tablica 1: Glavni indikatori razvoja sektora turizma u Hrvatskoj

Godina	1980.	1985.	1990.	1995.	2000.	2005.	2010.	2015.
Broj kreveta (u 000)	692	820	863	609	710	909	910	1029
Broj turista (u 000)	7929	10125	8498	2438	7136	9995	10604	14343
Broj noćenja (u 000)	53600	67665	52523	12885	39183	51421	56416	71605
Prosječan broj noćenja po krevetu	77	83	61	21	55	57	62	70
Prosječan broj noćenja po dolasku turista	6,80	6,7	6,2	5,3	5,5	5,1	5,3	5

Izvor: Ministarstvo turizma, https://mint.gov.hr/UserDocsImages//AA_2018_c-dokumenti//180608_HTZTUBENG_2017.PDF

Sadržaj **Tablice 1** je u nastavku prikazan kroz 5 grafikona. Prema **Slici 4** vidljivo je kako je broj dolazaka turista značajno porastao od 1980. do 2015. godine.




Slika 4: Broj dolazaka turista u milijunima za razdoblje od 1980. do 2015.

Izvor: Izrada autora prema podacima sa stranice Ministarstva turizma,

https://mint.gov.hr/UserDocsImages//AA_2018_c-dokumenti//180608_HTZTUBENG_2017.PDF

Broj noćenja turista, čije je kretanje od 1980. do 2015. prikazano na **Slici 5** se također povećao. U 1980. je iznosio 53 600 milijuna noćenja, a u 2015. brojka je porasla na čak 71 605 milijuna noćenja.




Slika 5: Broj noćenja turista u milijunima za razdoblje od 1980. do 2015.

Izvor: Izrada autora prema podacima sa stranice Ministarstva turizma,

https://mint.gov.hr/UserDocsImages//AA_2018_c-dokumenti//180608_HTZTUBENG_2017.PDF


Još jedno povećanje, tj. broj kreveta, od 1980. do 2015. godine, prikazano je na **Slici 6**. U 1980. broj kreveta bio je 692 milijuna, a u 2015. ovaj indikator porastao je na 1029 milijuna.



Slika 6: Broj kreveta u milijunima za razdoblje od 1980. do 2015.

Izvor: Izrada autora prema podacima sa stranice Ministarstva turizma,

https://mint.gov.hr/UserDocsImages//AA_2018_c-dokumenti//180608_HTZTUBENG_2017.PDF




Slika 7: Prosječan broj noćenja po krevetu za razdoblje od 1980. do 2015.

Izvor: Izrada autora prema podacima sa stranice Ministarstva turizma,

https://mint.gov.hr/UserDocsImages//AA_2018_c-dokumenti//180608_HTZTUBENG_2017.PDF

Prosječan broj noćenja po krevetu, čije kretanje za razdoblje od 1980. do 2015. godine je prikazano na **Slici 7**, za razliku od prethodno navedenih indikatora bilježi pad, i to sa 77 noćenja po krevetu u 1980. na 70. noćenja po krevetu u 2015. godini. Ovo je rezultat većeg rasta broja kreveta u periodu od 1980. do 2015. nego što je bio rast noćenja. I na kraju posljednji indikator, prosječan broj noćenja po dolasku turista, prikazan na **Slici 8**, bilježi pad sa 6,8 u 1980. na 5 u 2015. godini.



Slika 8: Prosječan broj noćenja po dolasku turista za razdoblje od 1980. do 2015.

Izvor: Izrada autora prema podacima sa stranice Ministarstva turizma,

https://mint.gov.hr/UserDocsImages//AA_2018_c-dokumenti//180608_HTZTUBENG_2017.PDF

Republika Hrvatska više od svih ostalih članica Europske unije ovisi o turizmu, što dokazuje udio prihoda od 17% u ukupnom BDP-u. Bitno je istaknuti da je to najviši prihod u odnosu na sve ostale zemlje članice Europske unije, u kojima je prosjek 2,3% (Marić, Samardžić i Protrka, 2017, str. 302). Zaključno, gledajući svih pet indikatora, kao i udio prihoda od turizma u BDP-u, sektor turizma u Hrvatskoj je narastao i postoji osnovana sumnja za potencijalno javljanje nizozemske bolesti.

4. EMPIRIJSKO ISTRAŽIVANJE O POSTOJANJU „DUTCH DISEASE“ U RH


Kako bi analiza postojanja tj. nepostojanja „Dutch Disease“ u Hrvatskoj bila moguća, potrebno je prvotni model Corden-a i Neary-a (1982), koji u svom radu govore o naglom uzletu energetskog sektora, prilagoditi.

Tako, korištenjem terminologije spomenutih autora, Copeland (1991, str. 518) razlikuje dva učinka naglog rasta sektora turizma: izravan učinak odnosno povećanje cijena usluga, uz održavanje domaće potrošnje konstantnom i neizravni učinak tj. SE, koji je posljedica promjena u domaćoj potrošnji usluga uzrokovane realnom promjenom dohotka. Autor navodi da, ako su usluge uobičajena dobra, SE pojačava direktan učinak, a time i dalje povećava blagostanje dobiveno rastom turizma. U suprotnom slučaju, neizravni učinak odnosno SE se javlja ako su usluge inferiorno dobro (dobro čija se potražnja smanjuje kad dohodak raste, i raste kad dohodak pada). Izravni učinak mora dominirati ako je tržište stabilno.

4.1. Rast potražnje i priljeva deviza u turističkom sektoru i realna aprecijacija kune

Kako bi se analizom podataka pokazalo vodi li rast potražnje i priljeva deviza u turističkom sektoru do realne aprecijacije kune koristit će se linearna regresijska analiza. Rast potražnje i priljeva deviza u turističkom sektoru će u nastavku biti prikazan u obliku prihoda od turizma, a realna aprecijacija kune u obliku realnog efektivnog tečaja. Da bismo prihvatili ovu hipotezu trebala bi postojati negativna veza prihoda od turizma i realnog efektivnog tečaja. Npr. rast prihoda od turizma trebao bi utjecati na pad realnog efektivnog tečaja tj. zaključilo bi se da je došlo do aprecijacije hrvatske kune.

Analiza će se vršiti koristeći podatke o prihodima od turizma i podatke realnog efektivnog tečaja kune. Podaci o indeksiranom realnom efektivnom tečaju sa baznom godinom 2010. iz baze podataka Svjetske banke kao zavisna varijabla odnosno ona koju se želi objasniti i podaci o prihodima od turizma iz baze podataka Hrvatske narodne banke kao nezavisna varijabla odnosno objašnjavajuća. Podaci obuhvaćaju razdoblje od 2002. do 2016. godine.



Slika 9: Odnos prihoda od turizma i realnog efektivnog tečaja

Izvor: Izrada autora

Na **Slici 9** prikazan je odnos prihoda od turizma i realnog efektivnog tečaja. Rezidualna vrijednost prikazana je na y os-i (realni efektivni tečajsa baznom 2010. godinom), a nezavisna odnosno objašnjavajuća na x osi (prihod od turizma u milijunima eura). Moguće je indeksirati i podatke prihoda od turizma u milijunima eura, ali se rezultati analize značajno ne mijenjaju.

U **Tablici 2** prikazan je koeficijent determinacije modela $R^2=0,116$ i korigirani koeficijent determinacije koji iznosi 0,048. Koeficijent determinacije pokazuje da je 11,6% ukupnog zbroja kvadrata odstupanja indeksiranog realnog efektivnog tečaja kune (2010=100) od svoje aritmetičke sredine objašnjeno ovom regresijom, a 4,8% ako se korigira za gubitke u stupnjevima slobode. Standardna greška regresije je 3,44 što ukazuje na to da model nema statističku signifikantnost kao cjelina, ali to će se tek potvrditi sa podacima iz ANOVA tablice.

Tablica 2: Koeficijent determinacije modela odnosa prihoda od turizma i realnog efektivnog tečaja

Model Summary ^b				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,341 ^a	,116	,048	3,4440618

a. Predictors: (Constant), Prihodi od turizma u milijunima Eura

b. Dependent Variable: Real effective exchange rate index (2010 = 100)

Izvor: Izrada autora

Tablica 3: ANOVA tablica odnosa prihoda od turizma i realnog efektivnog tečaja

ANOVA ^a					
Model	Sum of Squares	df	Mean Square	F	Sig.
1 Regression	20,263	1	20,263	1,708	,214 ^b
Residual	154,200	13	11,862		
Total	174,463	14			

a. Dependent Variable: Real effective exchange rate index (2010 = 100)

b. Predictors: (Constant), Prihodi od turizma u milijunima Eura

Izvor: Izrada autora

Prema **Tablici 3** vidi se da model nije značajan pri razini od 5% signifikantnosti.

Vrijednosti parametara i jednadžba modela dobiveni su iz **Tablice 4**. Jednadžba modela glasi:

$$\hat{Y}_i = 89,030 + 0,001X_i$$

Parametar β_0 pokazuje da ukoliko bi prihodi od turizma u milijunima eura iznosili 0, indeks realnog efektivnog tečaja (2010=100) iznosio bi 89,030. Parametar β_1 pokazuje da ukoliko bi prihodi od turizma u milijunima eura porasli za jednu jedinicu, odnosno za jedan milijun eura, onda bi indeks realnog efektivnog tečaja (2010=100) porastao za 0,001. Standardizirani regresijski koeficijenti pokazuju relativni utjecaj nezavisne na zavisnu varijablu. Standardizirana vrijednost parametara pokazuje za koliko će se standardnih devijacija promijeniti zavisna varijabla ako nezavisna varijabla poraste za jednu standardnu devijaciju. Ocijenjeni standardizirani regresijski model glasi:

$$\hat{Y}_i = 0,341X_i$$

To znači da će, ukoliko prihodi od turizma porastu u milijunima eura za jednu svoju standardnu devijaciju, indeks realnog efektivnog tečaja (2010=100) porasti će za 0,341 svojih standardnih devijacija.

Tablica 4: Parametri modela odnosa prihoda od turizma i realnog efektivnog tečaja

Model	Coefficients ^a						
	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
(Constant)	89,030	5,468		16,282	,000	77,217	100,843
Prihodi od turizma u milijunima Eura	,001	,001	,341	1,307	,214	-,001	,003

a. Dependent Variable: Real effective exchange rate index (2010 = 100)

Izvor: Izrada autora

Intervalna procjena ocjenjenih parametara uz 95% pouzdanosti prikazana je u desnom dijelu **Tablice 4.**

Može se donijeti zaključak o odbijanju prve hipoteze, odnosno o tome kako negativna veza između prihoda od turizma i realnog efektivnog tečaja ne postoji. Upravo suprotno, model prikazuje pozitivnu vezu, tako da u Hrvatskoj povećanje prihoda od turizma nije uzrokovalo aprecijaciju valute. „Spending effect“ se u Hrvatskoj nije pojavio.


4.2. Direktna deindustrijalizacija

Kako bi se analizom podataka pokazalo postoji li RME u Hrvatskoj (direktna deindustrijalizacija) stavit će se u odnos kretanje prihoda od turizma u milijunima eura i kretanje broja zaposlenih u „tradable“ i „non-tradable“ sektoru prema NKD (Nacionalnoj klasifikaciji djelatnosti). Podaci o broju zaposlenih po djelatnostima za razdoblje od 2002. godine do 2007. godine su klasificirani prema NKD 2002., a podaci od 2007. do 2016. prema NKD 2007. Podaci za kretanje prihoda od turizma su preuzeti iz platne bilance za kretanje roba i usluga, a podaci o broju zaposlenih u pojedinom sektoru sa stranice Državnog zavoda za statistiku (iz statističkih informacija, kretanje broja zaposlenih po djelatnostima tj. NKD). Pod zaposlene u „tradable“ sektoru uključeni su zaposleni u djelatnostima poljoprivrede i industrije bez građevine, a pod zaposlene u „non-tradable“ sektoru uključeni su zaposleni u ostalim djelatnostima. Kada bi postojala direktna deindustrijalizacija uzrokovana nizozemskom bolesti, trebalo bi biti vidljivo kretanje radne snage iz „tradable“ u „non-

tradable“ sektor, odnosno rast prihoda od turizma uzrokovao bi pad zaposlenih u „tradable“ sektoru i rast zaposlenih u „non-tradable“ sektoru.

4.2.1. Odnos zaposlenih u „tradable“ sektoru i prihoda od turizma

Na **Slici 10** prikazan je odnos broja zaposlenih u „tradable“ sektoru i prihoda od turizma u milijunima eura. Rezidualna vrijednost prikazana je na y os-i (broj zaposlenih u „tradable“ sektoru), a nezavisna odnosno objašnjavajuća na x osi (prihod od turizma u milijunima eura).



Slika 10: Odnos broja zaposlenih u "tradable" sektoru i prihoda od turizma

Izvor: Izrada autora

U **Tablici 5** prikazan je koeficijent determinacije modela $R^2=0,534$ i korigirani koeficijent determinacije koji iznosi 0,498. Koeficijent determinacije pokazuje da je 53,4% ukupnog zbroja kvadrata odstupanja broja zaposlenih u „tradable“ sektoru od svoje aritmetičke sredine objašnjeno ovom regresijom, a 49,8% ako se korigira za gubitke u stupnjevima slobode. Standardna greška regresije je 27676,103. S obzirom na vrijednost korigiranog koeficijenta determinacije koja je blizu vrijednosti 0,5 možemo zaključiti kako je model u cjelini reprezentativan.

Tablica 5: Koeficijent determinacije modela odnosa broja zaposlenih u "tradable" sektoru i prihoda od turizma

Model Summary ^b				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,731 ^a	,534	,498	27676,103

a. Predictors: (Constant), Prihodi od turizma u milijunima eura

Izvor: Izrada autora

Tablica 6: ANOVA tablica odnosa broja zaposlenih u "tradable" sektoru i prihoda od turizma

ANOVA ^a					
Model	Sum of Squares	df	Mean Square	F	Sig.
Regression	11422575422,544	1	11422575422,544	14,913	,002 ^b
Residual	9957566499,056	13	765966653,774		
Total	21380141921,600	14			

a. Dependent Variable: Broj zaposlenih u "tradable" sektoru

b. Predictors: (Constant), Prihodi od turizma u milijunima eura

Izvor: Izrada autora

Tablica 7: Parametri modela odnosa broja zaposlenih u "tradable" sektoru i prihoda od turizma

Model	Unstandardized Coefficients		Standardized Coefficients	T	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
(Constant)	545847,267	3940,532		12,422	,000	450919,519	640775,015
1 Prihodi od turizma u milijunima eura	-25,411	6,580	-,731	-3,862	,002	-39,627	-11,195

a. Dependent Variable: Broj zaposlenih u "tradable" sektoru

Izvor: Izrada autora

Prema **Tablici 6** vidi se da je model statistički značajan pri razini signifikantnosti od 5%.

Vrijednosti parametara i jednačba modela dobiveni su iz **Tablice 7**. Jednačba modela glasi:

$$\hat{Y}_i = 545\,847,267 - 25,411X_i$$

Parametar β_0 pokazuje da ukoliko bi prihodi od turizma u milijunima eura iznosili 0, broj zaposlenih u „tradable“ sektoru bio bi 545 847. Parametar β_1 pokazuje da ukoliko bi prihodi od turizma u milijunima eura porasli za jednu jedinicu, odnosno za jedan milijun eura, onda bi broj zaposlenih u „tradable“ sektoru pao za 25. Standardizirani regresijski koeficijenti pokazuju relativan utjecaj nezavisne na zavisnu varijablu. Standardizirana vrijednost parametara pokazuje za koliko će se standardnih devijacija promijeniti zavisna varijabla ako nezavisna varijabla poraste za jednu standardnu devijaciju. Ocijenjeni standardizirani regresijski model glasi:

$$\hat{Y}_i = -0,731X_i$$


To znači da će, ukoliko prihodi od turizma porastu u milijunima eura za jednu svoju standardnu devijaciju, broj zaposlenih u „tradable“ sektoru“ pasti će za 0,731 svojih standardnih devijacija.

Intervalna procjena ocijenjenih parametara uz 95% pouzdanosti prikazana je u desnom dijelu **Tablice 7**.

Može se, dakle, zaključiti kako postoji negativna veza između prihoda od turizma i zaposlenih u „tradable“ sektoru, te se spomenuto, kao što je već ranije navedeno u radu, smatra simptomom nizozemske bolesti.

4.2.2. Odnos zaposlenih u „non-tradable“ sektoru i prihoda od turizma

Na **Slici 11** prikazan je odnos broja zaposlenih u „non-tradable“ sektoru i prihoda od turizma. Rezidualna vrijednost prikazana je na y os-i (broj zaposlenih u „non-tradable“ sektoru), a nezavisna odnosno objašnjavajuća na x osi (prihod od turizma u milijunima eura).



Slika 11: Odnos broja zaposlenih u "non-tradable" sektoru i prihoda od turizma

Izvor: Izrada autora

Na **Tablici 8** prikazan je koeficijent determinacije modela $R^2 = 0,361$ i korigirani koeficijent determinacije koji iznosi 0,312. Koeficijent determinacije pokazuje da je 36,1% ukupnog zbroja kvadrata odstupanja broja zaposlenih u „non-tradable“ sektoru od svoje aritmetičke sredine objašnjeno ovom regresijom, a 31,2% ako se korigira za gubitke u stupnjevima slobode. Standardna greška regresije je 44254,883. S obzirom na vrijednost korigiranog koeficijenta determinacije koja je manja od 0,5 možemo zaključiti kako model u cjelini nije reprezentativan.

Tablica 8: Koeficijent determinacije modela odnosa broja zaposlenih u "non-tradable" sektoru i prihoda od turizma

Model Summary ^b				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,601 ^a	,361	,312	44254,883

a. Predictors: (Constant), Prihodi od turizma u milijunima eura

b. Dependent Variable: Broj zaposlenih u "nontradable" sektoru

Izvor: Izrada autora

Prema **Tablici 9** vidi se da je model statistički značajan pri razini signifikantnosti od 5%.

Vrijednosti parametara i jednadžba modela dobiveni su iz **Tablice 10**. Jednadžba modela glasi:

$$\hat{Y}_i = 852\,773,398 + 28,517X_i$$

Parametar β_0 pokazuje da ukoliko bi prihodi od turizma u milijunima eura iznosili 0, broj zaposlenih u „non-tradable“ sektoru bio bi 852 773. Parametar β_1 pokazuje da ukoliko bi prihodi od turizma u milijunima eura porasli za jednu jedinicu, odnosno za jedan milijun eura, onda bi broj zaposlenih u „non-tradable“ sektoru porastao za 28. Standardizirani regresijski koeficijenti pokazuju relativni utjecaj nezavisne na zavisnu varijablu. Standardizirana vrijednost parametara pokazuje za koliko će se standardnih devijacija promijeniti zavisna varijabla ako nezavisna varijabla poraste za jednu standardnu devijaciju. Ocijenjeni standardizirani regresijski model glasi:

$$\hat{Y}_i = 0,601X_i$$

To znači da će, ukoliko prihodi od turizma porastu u milijunima eura za jednu svoju standardnu devijaciju, broj zaposlenih u „non-tradable“ sektoru porast će za 0,601 svojih standardnih devijacija.

Tablica 9: ANOVA tablica odnosa broja zaposlenih u "non-tradable" sektoru i prihoda od turizma

ANOVA ^a					
Model	Sum of Squares	df	Mean Square	F	Sig.
Regression	14385761266,010	1	14385761266,010	7,345	,018b
Residual	25460430853,590	13	1958494681,045		
Total	39846192119,600	14			

a. Dependent Variable: Broj zaposlenih u "nontradable" sektoru

b. Predictors: (Constant), Prihodi od turizma u milijunima eura

Izvor: Izrada autora

Intervalna procjena ocijenjenih parametara uz 95% pouzdanosti prikazana je u desnom dijelu **Tablice 10**.

Tablica 10: Parametri modela odnosa broja zaposlenih u "non-tradable" sektoru i prihoda od turizma

Coefficients ^a							
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
(Constant)	852773,398	70262,173		12,137	000	700981,202	1004565,594
Prihodi od turizma u milijunima eura	28,517	10,522	,601	2,710	018	5,786	51,249

a. Dependent Variable: Broj zaposlenih u "nontradable" sektoru

Izvor: Izrada autora

Na temelju prethodno istaknutog druga hipoteza može se djelomično prihvatiti odnosno može se donijeti zaključak o tome kako postoji negativna veza između prihoda od turizma i broja zaposlenih u „tradable“ sektoru za Hrvatsku jer je model reprezentativan. Međutim, ne može se donijeti zaključak o tome kako postoji pozitivna veza između prihoda od turizma i broja zaposlenih u „non-tradable“ sektoru za Hrvatsku jer model nije reprezentativan.


4.3. Indirektna deindustrijalizacija

Zadnji dio empirijskog dijela prikazat će je li došlo do indirektne deindustrijalizacije u Republici Hrvatskoj. Realna aprecijacija valute, odnosno deprecijacija realnog efektivnog tečaja kune (ovdje će se koristiti indeksirane vrijednosti kao i u okviru prve hipoteze), trebala bi utjecati na pad konkurentnosti „tradable“ sektora (ovdje će se za konkurentnost spomenutog sektora koristiti podaci o izvozu istog). Dakle ako realni efektivni tečaj pada, i izvoz „tradable“ sektora bi trebao padati. Također, promatrat će se odnos plaća koje bi trebale rasti kada konkurentnost „tradable“ sektora pada (odnosno kada pada izvoz „tradable“ sektora). Podaci o prosječnoj plaći za pojedini sektor („tradable“, „non-tradable“ i ukupno) izračunati su na temelju podataka, sa stranica Državnog zavoda za statistiku o kretanju prosječnih plaća po djelatnostima odnosno po Nacionalnoj klasifikaciji djelatnosti. Podaci o kretanju prosječnih plaća po djelatnostima za razdoblje od 2002. godine do 2007. godine su klasificirani prema NKD 2002., a podaci od 2007. do 2016. prema NKD 2007. Prosječna plaća u „tradable“ sektoru dobivena je kao prosjek plaća za djelatnosti poljoprivrede i industrije bez građevine. Prosječna plaća u „non-tradable“ sektoru dobivena je kao prosjek plaća za ostale djelatnosti odnosno sve djelatnosti izuzev korištenih za izračun prosječne plaće „tradable“ sektora. Podaci o kretanju izvoza „tradable“ sektora su također preuzeti sa stranica

Državnog zavoda za statistiku. Izvoz „tradable“ sektora je također dobiven na temelju Nacionalne klasifikacije djelatnosti (2002. i 2007.), odnosno u njega se ubraja izvoz koji je nastao iz djelatnosti poljoprivrede i industrije bez građevine.

4.3.1. Odnos realnog efektivnog tečaja kune i izvoza „tradable“ sektora

Na **Slici 12** prikazan je odnos realnog efektivnog tečaja kune i izvoza „tradable“ sektora. Rezidualna vrijednost prikazana je na y os-i (izvoz „tradable“ sektora u tisućama kuna), a nezavisna odnosno objašnjavajuća na x osi (indeks realnog efektivnog tečaja kune sa baznom 2010. godinom).



Slika 12: Odnos realnog efektivnog tečaja kune i izvoza "tradable" sektora

Izvor: Izrada autora

Tablica 11: Koeficijent determinacije modela odnosa realnog efektivnog tečaja kune i izvoza "tradable" sektora

Model Summary ^b				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,257 ^a	,066	-,006	15545692,58218

a. Predictors: (Constant), Realni efektivni tečaj

b. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

U **Tablici 11** prikazan je koeficijent determinacije modela $R^2 = 0,066$ i korigirani koeficijent determinacije koji iznosi -0,006. Koeficijent determinacije pokazuje da je 6,6% ukupnog zbroja kvadrata odstupanja izvoza „tradable“ sektora od svoje aritmetičke sredine objašnjeno ovom regresijom. Standardna greška regresije je 15545692,58. S obzirom na vrijednost

korigiranog koeficijenta determinacije koja je manja od 0,5 možemo zaključiti kako model u cjelini nije reprezentativan.

Tablica 12: ANOVA tablica odnosa realnog efektivnog tečaja kune i izvoza "tradable" sektora

ANOVA ^a						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	221772902772058,280	1	221772902772058,280	,918	,356 ^b
	Residual	3141691252175255,500	13	241668557859635,030		
	Total	3363464154947314,000	14			

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

b. Predictors: (Constant), Realni efektivni tečaj

Izvor: Izrada autora

Tablica 13: Parametri modela odnosa realnog efektivnog tečaja kune i izvoza "tradable" sektora

Coefficients ^a							
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
1 (Constant)	-43924068,288	113154708,108		-,388	,704	-288379953,015	200531816,439
Realni efektivni tečaj	1127463,480	1176950,826	,257	,958	,356	-1415184,195	3670111,154

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

Prema **Tablici 12** vidi se da model nije statistički značajan pri razini signifikantnosti od 5%.

Vrijednosti parametara i jednadžba modela dobiveni su iz **Tablice 13**. Jednadžba modela glasi:

$$\hat{Y}_i = -43924068,288 + 1127463,48X_i$$

Parametar β_0 pokazuje da ukoliko bi realni efektivni tečaj (indeks sa baznom 2010. godinom) iznosio 0, izvoz „tradable“ sektora iznosio bi -43924068,288 tisuće kuna. Parametar β_1 pokazuje da ukoliko bi realni efektivni tečaj (indeks sa baznom 2010. godinom) porastao za jednu jedinicu, onda bi izvoz „tradable“ sektora porastao za 1127463,48 tisuća kuna. Standardizirani regresijski koeficijenti pokazuju relativni utjecaj nezavisne na zavisnu varijablu. Standardizirana vrijednost parametara pokazuje za koliko će se standardnih devijacija promijeniti zavisna varijabla ako nezavisna varijabla poraste za jednu standardnu devijaciju.

Ocijenjeni standardizirani regresijski model glasi:

$$\hat{Y}_i = 0,257X_i$$


To znači da će, ukoliko realni efektivni tečaj (indeks sa baznom 2010. godinom) poraste za jednu svoju standardnu devijaciju, izvoz „tradable“ sektora u tisućama kuna porast za 0,257 svojih standardnih devijacija.

Intervalna procjena ocjenjenih parametara uz 95% pouzdanosti prikazana je u desnom dijelu **Tablice 13**.

Intervalna procjena ocjenjenih parametara uz 95% pouzdanosti prikazana je u desnom dijelu **Tablice 13**.

4.3.2. Odnos prosječne plaće i izvoza „tradable“ sektora

Na **Slici 13** prikazan je odnos prosječne plaće u Hrvatskoj za oba sektora zajedno („tradable“ i „non-tradable“) i izvoza „tradable“ sektora. Rezidualna vrijednost prikazana je na y os-i (izvoz „tradable“ sektora u tisućama kuna), a nezavisna odnosno objašnjavajuća na x osi (prosječna plaća za oba sektora u kunama).



Slika 13: Odnos prosječne plaće i izvoza "tradable" sektora

Izvor: Izrada autora

Tablica 14: Koeficijent determinacije modela odnosa prosječne plaće i izvoza "tradable" sektora

Model Summary ^b				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,863 ^a	,744	,724	8136766,98577

a. Predictors: (Constant), Prosječne plaće

b. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

Na **Tablici 14** prikazan je koeficijent determinacije modela $R^2 = 0,744$ i korigirani koeficijent determinacije koji iznosi 0,724. Koeficijent determinacije pokazuje da je 74,4% ukupnog zbroja kvadrata odstupanja izvoza „tradable“ sektora od svoje aritmetičke sredine objašnjeno ovom regresijom, a 72,4% ako se korigira za gubitke u stupnjevima slobode. Standardna greška regresije je 8136766,98. S obzirom na vrijednost korigiranog koeficijenta determinacije koja je veća od 0,5 možemo zaključiti kako je model u cjelini reprezentativan.

Tablica 15: ANOVA tablica odnosa prosječne plaće i izvoza "tradable" sektora

ANOVA ^a						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2502773454198276,000	1	2502773454198276,000	37,802	,000 ^b
	Residual	860690700749038,000	13	66206976980695,234		
	Total	3363464154947314,000	14			

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

b. Predictors: (Constant), Prosječne plaće

Izvor: Izrada autora

Prema **Tablici 15** vidi se da je model statistički značajan pri razini signifikantnosti od 5%.

Vrijednosti parametara i jednadžba modela dobiveni su iz **Tablice 16**. Jednadžba modela glasi:

$$\hat{Y}_i = -31378135,053 + 13586,177X_i$$

Može se zaključiti kako postoji pozitivna veza između kretanja ukupnih (za sve djelatnosti) prosječnih plaća na godišnjoj razini i izvoza „tradable“ sektora.

Tablica 16: Parametri modela odnosa prosječne plaće i izvoza "tradable" sektora


Coefficients ^a							
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
1 (Constant)	-31378135,053	15719620,231		-1,996	,067	-65338309,892	2582039,785
Prosječne plaće	13586,177	2209,726	,863	6,148	,000	8812,355	18360,000

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

4.3.3. Odnos prosječne plaće u „tradable“ sektoru i izvoza „tradable“ sektora

Na **Slici 14** prikazan je odnos prosječne plaće u Hrvatskoj za „tradable“ sektor i izvoza „tradable“ sektora. Rezidualna vrijednost prikazana je na y os-i (izvoz „tradable“ sektora u tisućama kuna), a nezavisna odnosno objašnjavajuća na x osi (prosječna plaća za „tradable“ sektor u kunama).



Slika 14: Odnos prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora

Izvor: Izrada autora

Tablica 17: Koeficijent determinacije modela odnosa prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora

Model Summary ^b				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,877 ^a	,770	,752	7716642,53596

a. Predictors: (Constant), Prosječne plaće "tradable" sektora

b. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

U **Tablici 17** prikazan je koeficijent determinacije modela $R^2 = 0,770$ i korigirani koeficijent determinacije koji iznosi 0,752. Koeficijent determinacije pokazuje da je 77% ukupnog zbroja kvadrata odstupanja izvoza „tradable“ sektora od svoje aritmetičke sredine objašnjeno ovom regresijom, a 75,2% ako se korigira za gubitke u stupnjevima slobode. Standardna greška regresije je 7716642,53. S obzirom na vrijednost korigiranog koeficijenta determinacije koja je veća od 0,5 možemo zaključiti kako je model u cjelini reprezentativan.

Tablica 18: ANOVA tablica odnosa prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora

ANOVA ^a						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2589358718585585,000	1	2589358718585585,000	43,485	,000 ^b
	Residual	774105436361729,000	13	59546572027825,305		
	Total	3363464154947314,000	14			

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

b. Predictors: (Constant), Prosječne plaće "tradable" sektora

Izvor: Izrada autora

Prema **Tablici 18** vidi se da je model statistički značajan pri razini signifikantnosti od 5%.

Vrijednosti parametara i jednadžba modela dobiveni su iz **Tablice 19**. Jednadžba modela glasi:

$$\hat{Y}_i = -21615137,738 + 11678,218X_i$$

Može se zaključiti kako postoji pozitivna veza između kretanja prosječnih plaća „tradable“ sektora na godišnjoj razini i izvoza „tradable“ sektora. Navedeno bi značilo da rast plaća u „tradable“ sektoru utječe na rast izvoza „tradable“ sektora, a ne pad kao što bi to bilo u slučaju postojanja nizozemske bolesti.

Tablica 19: Parametri modela odnosa prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora


Coefficients ^a							
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	-21615137,738	13195872,267	-1,638	,125	-50123086,579	6892811,103
	Prosječne plaće "tradable" sektora	11678,218	,877	6,594	,000	7852,291	15504,146

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

4.3.4. Odnos prosječne plaće u „non-tradable“ sektoru i izvoza „tradable“ sektora

Na **Slici 15** prikazan je odnos prosječne plaće u Hrvatskoj za „non-tradable“ sektor i izvoza „tradable“ sektora. Rezidualna vrijednost prikazana je na y os-i (izvoz „tradable“ sektora u tisućama kuna), a nezavisna odnosno objašnjavajuća na x osi (prosječna plaća za „non-tradable“ sektor u kunama).



Slika 15: Odnos prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora

Izvor: Izrada autora

U **Tablici 20** prikazan je koeficijent determinacije modela $R^2 = 0,698$ i korigirani koeficijent determinacije koji iznosi 0,674. Koeficijent determinacije pokazuje da je 69,8% ukupnog zbroja kvadrata odstupanja izvoza „tradable“ sektora od svoje aritmetičke sredine objašnjeno ovom regresijom, a 67,4% ako se korigira za gubitke u stupnjevima slobode. Standardna greška regresije je 8844081,24. S obzirom na vrijednost korigiranog koeficijenta determinacije koja je veća od 0,5 možemo zaključiti kako je model u cjelini reprezentativan.

Tablica 20: Koeficijent determinacije modela odnosa prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora

Model Summary ^b				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,835 ^a	,698	,674	8844081,24426

a. Predictors: (Constant), Prosječne plaće "non-tradable" sektora

b. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

Tablica 21: ANOVA tablica odnosa prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora

ANOVA ^a						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2346633105231603,000	1	2346633105231603,000	30,001	,000 ^b
	Residual	1016831049715711,000	13	78217773055054,690		
	Total	3363464154947314,000	14			

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

b. Predictors: (Constant), Prosječne plaće "non-tradable" sektora

Izvor: Izrada autora

Prema **Tablici 21** vidi se da je model statistički značajan pri razini signifikantnosti od 5%.

Tablica 22: Parametri modela odnosa prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora

Coefficients ^a							
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
1 (Constant)	-43313721,927	19798297,400		-2,188	,048	-86085343,081	-542100,773
Prosječne plaće "non-tradable" sektora	15995,711	2920,342	,835	5,477	,000	9686,696	22304,726

a. Dependent Variable: Izvoz "tradable" sektora u 000 kn

Izvor: Izrada autora

Vrijednosti parametara i jednadžba modela dobiveni su iz **Tablice 22**. Jednadžba modela glasi:

$$\hat{Y}_i = -43313721,927 + 15995,711X_i$$

Može se zaključiti kako postoji pozitivna veza između kretanja prosječnih plaća „non-tradable“ sektora na godišnjoj razini i izvoza „tradable“ sektora. Navedeno bi značilo da rast plaća u „non-tradable“ sektoru utječe na rast izvoza „tradable“ sektora, a ne pad kao što bi to bilo u slučaju postojanja nizozemske bolesti.

Dakle, treća hipoteza se odbija. U Hrvatskoj, u razdoblju od 2002. do 2016. godine nije došlo do indirektno deindustrijalizacije. Rast plaća nije uzrokovao deindustrijalizaciju odnosno pad izvoza „tradable“ sektora.

5. ZAKLJUČAK

S empirijskog stajališta cilj istraživanja ovog rada bio je na temelju metodološki jednostavne obrade podataka istražiti prisutno nizozemkse bolesti u Hrvatskoj odnosno je li nagli rast sektora turizma hrvatskog gospodarstva odvuкао resurse iz ostalih sektora i na taj način utjecao na smanjenu konkurentnost i deindustrijalizaciju. Dakle, cilj je bio donijeti zaključak o tome postoji li nizozemska bolest uzrokovana naglim rastom sektora turizma u Republici Hrvatskoj. Kako bi se cilj istraživanja ispunio, u empirijskom dijelu rada provedena je linearna regresijska analiza.

Prvo je ispitan odnos rasta potražnje i priljeva deviza u turističkom sektoru koji potencijalno dovodi do aprecijacije realnog efektivnog tečaja i donesen je zaključak o tome kako ne postoji negativan odnos među dvjema promatranim pojavama. Ukoliko bi rast prihoda od turizma vodio padu realnog efektivnog tečaja odnosno jačanju valute, moglo bi se reći da se u Hrvatskoj javlja SE. Upravo suprotno efekt potrošnje nije djelovao preko aprecijacije kune, nego se baš suprotno, javila se deprecijacija. Dakle unatoč rastu sektora turizma, efekt potrošnje se nije pojavio.

Drugo, ispitan je odnos broja zaposlenih u „tradable“ i „non-tradable“ sektoru sa prihodima turizma. Učinak seljenja resursa (RME) očitovao bi se na način da rast prihoda od turizma utječe na pad broja zaposlenih u „tradable“ sektoru i rast broja zaposlenih u „non-tradable“ sektoru. Direktna deindustrijalizacija bi se tako očitovala na način da rast sektora turizma odvlači radnike iz ostalih sektora gospodarstva u sektor turizma. Regresijskom analizom je donesen zaključak o negativnoj vezi između rasta prihoda od turizma i zaposlenih u „tradable“ sektoru, kao i zaključak o pozitivnoj vezi između rasta prihoda od turizma i zaposlenih u „non-tradable“ sektoru. Međutim, model koji stavlja u odnos zaposlene u „non-tradable“ sektoru i prihode od turizma se pokazao kao nereprezentativan. Stoga se druga hipoteza samo djelomično prihvaća.

Konačno, kao treće, ispitan je odnos realne aprecijacije kune i rasta plaća (zbog rasta u sektoru usluga) sa izvozom „tradable“ sektora, kako bi se istražilo je li u Hrvatskoj došlo do indirektna industrijalizacije, što bi se očitovalo kroz odnos realnog efektivnog deviznog tečaja i izvoza „tradable“ sektora. Pad realnog efektivnog tečaja, odnosno aprecijacija kune bi utjecala na smanjenje izvoza „tradable“ sektora. Također na smanjenje izvoza „tradable“ sektora, u slučaju indirektna industrijalizacije, trebao bi utjecati i rast plaća. Nakon provedene linearne regresijske analize, može se zaključiti kako postoji pozitivna veza između kretanja prosječnih plaća „non-tradable“ sektora na godišnjoj razini i izvoza „tradable“ sektora.

Navedeno bi značilo da rast plaća u „non-tradable“ sektoru utječe na rast izvoza „tradable“ sektora, a ne pad kao što bi bilo u slučaju postojanja nizozemske bolesti. Stoga, u Hrvatskoj, u razdoblju od 2002. do 2016. godine nije došlo do indirektne deindustrijalizacije. Rast plaća nije uzrokovao indirektnu deindustrijalizaciju odnosno pad izvoza „tradable“ sektora.

Konačan zaključak ovog metodološki jednostavnog istraživanja, je da u Hrvatskoj ne postoje simptomi nizozemske bolesti, ali ne mora značiti da, ukoliko se nagli rast sektora turizma u Hrvatskoj nastavi, u budućnosti neće doći do negativnih efekata nizozemske bolesti. Stoga je potrebno i dalje pratiti razvoj indikatora proučavanih u ovom radu. Međutim, ukoliko bi do nizozemske bolesti pak došlo, potrebno je znati koje politike koristiti kako bi se negativan utjecaj spriječio, kao i mjere prevencije, kako do pojave nizozemske bolesti uopće nebi došlo. Što se tiče monetarne politike, koja je do sada u Hrvatskoj za cilj imala ciljanje inflacije, može se primjeniti specifičnije ciljanje, odnosno ciljanje posebnog indeksa potrošačkih cijena koji ima veći udio cijena izvoznih dobara i/ili proizvodnih cijena. Što se tiče fiskalne politike, potrebno je ograničiti državnu potrošnju za koju se pokazalo da korelira sa porastom prihoda od resursa (u slučaju Hrvatske porastom prihoda od turizma). Dakle, rastom prihoda od turizma, rasla bi državna potrošnja. Mjere fiskalne politike su osnivanje posebnog rezervnog fonda (turističkog fonda) koji će služiti za ublažavanje efekta potrošnje i provođenje politike fiskalnog suficita. I konačno, što se tiče politike potrošnje, istu je potrebno usmjeravati na investicije koje će povećati produktivnost „non-tradable“ sektora (npr. investicije u infrastrukturu i investicije u ljudski kapital radi lakšeg savladavanja vještina korištenja novih tehnologija).

POPIS SLIKA

Slika 1: Indeksi fizičkog obujma industrijske proizvodnje za industriju ukupno u razdoblju od 2011. do 2017. godine (2015.=100)	12
Slika 2: „Dutch disease“	14
Slika 3: Indeksi proizvodnje, zaposlenih i proizvodnosti rada u industriji od 2007. do 2016.	25
Slika 4: Broj dolazaka turista u milijunima za razdoblje od 1980. do 2015.	27
Slika 5: Broj noćenja turista u milijunima za razdoblje od 1980. do 2015.	27
Slika 6: Broj kreveta u milijunima za razdoblje od 1980. do 2015.	28
Slika 7: Prosječan broj noćenja po krevetu za razdoblje od 1980. do 2015.	28
Slika 8: Prosječan broj noćenja po dolasku turista za razdoblje od 1980. do 2015.	29
Slika 9: Odnos prihoda od turizma i realnog efektivnog tečaja	31
Slika 10: Odnos broja zaposlenih u "tradable" sektoru i prihoda od turizma	34
Slika 11: Odnos broja zaposlenih u "non-tradable" sektoru i prihoda od turizma	37
Slika 12: Odnos izvoza realnog efektivnog tečaja kune i izvoza "tradable" sektora	40
Slika 13: Odnos prosječne plaće i izvoza "tradable" sektora	42
Slika 14: Odnos prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora	44
Slika 15: Odnos prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora	46

POPIS TABLICA

Tablica 1: Glavni indikatori razvoja sektora turizma u Hrvatskoj	26
Tablica 2: Koeficijent determinacije modela odnosa prihoda od turizma i realnog efektivnog tečaja.....	31
Tablica 3: ANOVA tablica odnosa prihoda od turizma i realnog efektivnog tečaja	32
Tablica 4: Parametri modela odnosa prihoda od turizma i realnog efektivnog tečaja	33
Tablica 5: Koeficijent determinacije modela odnosa broja zaposlenih u "tradable" sektoru i prihoda od turizma	35
Tablica 6: ANOVA tablica odnosa broja zaposlenih u "tradable" sektoru i prihoda od turizma	35
Tablica 7: Parametri modela odnosa broja zaposlenih u "tradable" sektoru i prihoda od turizma.....	35
Tablica 8: Koeficijent determinacije modela odnosa broja zaposlenih u "non-tradable" sektoru i prihoda od turizma	37
Tablica 9: ANOVA tablica odnosa broja zaposlenih u "non-tradable" sektoru i prihoda od turizma.....	38
Tablica 10: Parametri modela odnosa broja zaposlenih u "non-tradable" sektoru i prihoda od turizma.....	39
Tablica 11: Koeficijent determinacije modela odnosa realnog efektivnog tečaja kune i izvoza "tradable" sektora	40
Tablica 12: ANOVA tablica odnosa realnog efektivnog tečaja kune i izvoza "tradable" sektora	41
Tablica 13: Parametri modela odnosa realnog efektivnog tečaja kune i izvoza "tradable" sektora	41
Tablica 14: Koeficijent determinacije modela odnosa prosječne plaće i izvoza "tradable" sektora	42
Tablica 15: ANOVA tablica odnosa prosječne plaće i izvoza "tradable" sektora	43
Tablica 16: Parametri modela odnosa prosječne plaće i izvoza "tradable" sektora	43
Tablica 17: Koeficijent determinacije modela odnosa prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora.....	44
Tablica 18: ANOVA tablica odnosa prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora	45

Tablica 19: Parametri modela odnosa prosječne plaće u "tradable" sektoru i izvoza "tradable" sektora	45
Tablica 20: Koeficijent determinacije modela odnosa prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora.....	46
Tablica 21: ANOVA tablica odnosa prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora	46
Tablica 22: Parametri modela odnosa prosječne plaće u "non-tradable" sektoru i izvoza "tradable" sektora	47

LITERATURA

1. Barguelli, A., Ben-Salha, O. i Zamami, M. (2018): **Exchange Rate Volatility and Economic Growth**, Journal of Economic Integration, Vol. 33, No. 2, str. 1302-1336.
2. Bresser-Pereira, L. C. (2008): **The Dutch disease and its neutralization: a Ricardian approach**, Brazilian Journal of Political Economy, Vol. 28, No. 109, str. 47-71.
3. Capó, J. , Riera Font, A. i Rosselló Nadal, J. (2007): **Dutch Disease in Tourism Economies: Evidence from the Balearics and the Canary Islands**, Journal of Sustainable Tourism, , str. 615-627.
4. Chao, C., Hazari, B. H. et al. (2006): **Tourism, Dutch Disease and Welfare in an Open Dynamic Economy**, The Japanese Economic Review, Vol. 57, No. 4, str. 501-515.
5. Chen, P., et al. (2016): **Welfare effects of tourism-driven Dutch disease: The roles of international borrowings and factor intensity**, International Review of Economics and Finance
6. Copeland, R. (1991) : **Tourism, Welfare and De-industrialization in a Small Open Economy**, Economica, Vol. 58, No. 232, str. 515-529.
7. Corden, W. M. (1984): **Booming Sector and Dutch Disease Economics: Survey and Consolidation**, Oxford Economic Papers, Vol. 36, No. 3, str. 359-380.
8. Corden, W. M., Neary, J. P. (1982): **Booming Sector and De-Industrialisation in a Small Open Economy**, The Economic Journal, Vol. 92, No. 368, str. 825-848.
9. Corden, W. M. (2012): **The Dutch Disease in Australia Policy Options for a Three-Speed Economy**, Working Papers in Trade and Development, Australian National University, No 2012/10.
10. Deskar Škrbić, M. (2017): **Hrvatski turistički bum: dolazi li virus nizozemske bolesti**, Ekonomski lab, [Internet], raspoloživo na:
<https://arhivanalitika.hr/blog/hrvatski-turisticki-bum-dolazi-li-virus-nizozemske-bolesti/> [22.05.2018.].
11. Državni zavod za statistiku (2016): **Zaposleni prema područjima djelatnosti i po županijama: stanje 31. ožujka 2016. godine**, [Internet], raspoloživo na:
https://www.dzs.hr/Hrv_Eng/publication/2016/09-02-04_01_2016.htm [10.05.2018.].

12. Državni zavod za statistiku (2017): **Dolasci i noćenja turista u 2017. godini**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2017/04-03-02_01_2017.htm [10.05.2018.].
13. Državni zavod za statistiku (2017): **Hrvatska u brojkama 2017**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv_Eng/CroInFig/croinfig_2017.pdf [15.08.2018.].
14. Državni zavod za statistiku (2004): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv/publication/2004/4-2-4_1h2004.htm [28.08.2018.].
15. Državni zavod za statistiku (2005): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv/publication/2006/4-2-4_1h2006.htm [28.08.2018.].
16. Državni zavod za statistiku (2008): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv/publication/2008/4-2-4_1h2008.htm [28.08.2018.].
17. Državni zavod za statistiku (2010): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživona: https://www.dzs.hr/Hrv_Eng/publication/2010/04-02-04_01_2010.htm [28.08.2018.].
18. Državni zavod za statistiku (2012): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2012/04-02-04_01_2012.htm [28.08.2018.].
19. Državni zavod za statistiku (2014): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2014/04-02-03_01_2014.htm [28.08.2018.].
20. Državni zavod za statistiku (2016): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2016/04-02-02_01_2016.htm [28.08.2018.].
21. Državni zavod za statistiku (2017): **Robna razmjena Republike Hrvatske s inozemstvom**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2017/04-02-02_01_2017.htm [28.08.2018.].
22. Državni zavod za statistiku (2018): **Statističke informacije 2018**, [Internet], raspoloživo na: https://www.dzs.hr/Hrv_Eng/StatInfo/pdf/StatInfo2018.pdf [17.08.2018.].

23. Državni zavod za statistiku (2015): **Statističke informacije 2015**, [Internet],
raspoloživo na: https://www.dzs.hr/Hrv_Eng/StatInfo/pdf/StatInfo2015.pdf
24. Državni zavod za statistiku (2012): **Statističke informacije 2012**, [Internet],
raspoloživo na: https://www.dzs.hr/Hrv_Eng/StatInfo/pdf/StatInfo2012.pdf
25. Državni zavod za statistiku (2009): **Statističke informacije 2009**, [Internet],
raspoloživo na: https://www.dzs.hr/Hrv_Eng/StatInfo/pdf/StatInfo2009.pdf
26. Državni zavod za statistiku (2006): **Statističke informacije 2006**, [Internet],
raspoloživo na: https://www.dzs.hr/Hrv_Eng/StatInfo/pdf/StatInfo2006.pdf
27. Državni zavod za statistiku (2005): **Statističke informacije 2005**, [Internet],
raspoloživo na: https://www.dzs.hr/Hrv_Eng/StatInfo/pdf/StatInfo2005.pdf
28. Ebrahimzadeh, C. (2017): **Dutch Disease: Wealth Managed Unwisely**, IMF,
[Internet], raspoloživo na:
<https://www.imf.org/external/pubs/ft/fandd/basics/dutch.htm> [11.08.2018.].
29. Federico, I. S. (2015): **Tourism: Economic growth, employment and Dutch Disease**, Annals of Tourism Research, str. 172-189.
30. Forsyth, P., Dwyer, L. i Spurr, R. (2014): **Is Australian tourism suffering Dutch Disease?**, Annals of Tourism Research, str. 1-15.
31. Frankel, A. J. (2010): **The Natural Resource Curse: A Survey**, NBER Working Paper, No. 15836
32. Ghalia, T. i Fidrmuc, J. (2015): **The curse of tourism?**, Journal of Hospitality & Tourism Research, Vol. 20, No. 10, str. 1-15.
33. HNB (2015): **Tečajni režim**, [Internet], raspoloživo na: <https://www.hnb.hr/temeljne-funkcije/monetarna-politika/tečajni-rezim> [13.08.2018.].
34. Holzner, M. (2011): **Tourism and economic development: The beach disease?**, Tourism Management, str. 922-922.
35. Inchausti-Sintes (2015): **Tourism: Economic growth, employment and Dutch Disease**, Annals of Tourism Research, str. 172-189.
36. Ivanov, M. (2015): **Efekti intervalutnih odnosa na razvoj gospodarstva Hrvatske**
37. Jošić, H., Maček Pandak, F. (2017): **Nizozemska bolest u Bolivarijanskoj Republici Venezueli**, Noriria – časopis za održivi razvoj, No. 3, str. 125-137.
38. Kenell, L. (2008): **Dutch Disease and Tourism: The Case of Thailand**, Lund University.

39. Magud, N. i Sosa, S. (2010): **When and Why Worry About Real Exchange Rate Appreciation?, The Missing Link between Dutch Disease and Growth**, IMF Working Paper.
40. Marić, K., Samardžić, B. i Protrka, N. (2017): **Analiza turističkih pokazatelja i sigurnost u turizmu republike hrvatske te mogućnosti jačanja konkurentnosti hrvatskog turizma nakon ulaska u europsku uniju**, Znanstveno stručni časopis o obrazovanju za poduzetništvo, Vol. 7, No. 1, str. 301-318.
41. Ministarstvo turizma Republike Hrvatske (2018): **Tourism in figures 2017**, [Internet], raspoloživo na: https://mint.gov.hr/UserDocsImages//AA_2018_c-dokumenti//180608_HTZTUBHR_2017.PDF , [15.08.2018].
42. Nowak, J. i Sahli, M. (2007): **Coastal tourism and „Dutch disease“ in a small island economy**, Tourism Economics, str. 49-65.
43. Penava, M. i Družić, M. (2015): **Croatian industrial policy in the context of deindustrialisation**, str. 843-852.
44. Pratt, S (2015): **The economic impact of tourism in SIDS**, Annals of Tourism Research, str. 148-160.
45. Sheng, L., (2011): **Taxing tourism and subsidizing non-tourism: A welfare-enhancing solution to „Dutch Disease“**, Tourism Management, str. 1223-1228.
46. The World Bank (2010): **Dealing with Dutch Disease**, [Internet], raspoloživo na: <http://siteresources.worldbank.org/INTPREMNET/Resources/EP16.pdf> , [20.08.2018.].
47. Zelenika, R. (2000): **Metodologija i tehnologija izrade znanstvenog i stručnog djela**, Rijeka: Ekonomski fakultet.

SAŽETAK

Republika Hrvatska više od svih ostalih članica Europske unije ovisi o turizmu. Nizozemska bolest javlja se kada sektor gospodarstva koji naglo raste i ostvaruje veliki devizni priljev uzrokuje promjene u gospodarstvu poput re-alokacije proizvodnih faktora odnosno selidbe radnika iz „tradable“ u „non-tradable“ sektor, aprecijaciju realnog efektivnog tečaja, visoku nezaposlenost, rast realnih plaća i deindustrijalizaciju. Navedene promjene očituju se kroz pojavu „Spending Effect-a“ i „Resource Movement Effect-a“. Cilj ovog istraživanja bio je je na temelju jednostavne analize istražiti je li nagli rast sektora turizma hrvatskog gospodarstva odvuкао resurse iz ostalih sektora i na taj način utjecao na smanjenu konkurentnost i deindustrijalizaciju. Podaci o kretanju: zaposlenih u „tradable“ i „non-tradable“ sektoru, prihoda od turizma, realnog efektivnog tečaja, izvoza „tradable“ sektora i prosječne plaće spomenuta dva sektora obrađeni su linearnom regresijskom analizom na temelju koje je donesen zaključak kako nizozemska bolest nije zahvatila Hrvatsku. Unatoč tom zaključku, ne mora značiti da, ukoliko se nagli rast sektora turizma u Hrvatskoj nastavi, u budućnosti neće doći do negativnih efekata nizozemske bolesti.

Ključne riječi: nizozemska bolest, turizam, „Spending Effect“, „Resource Movement Effect“

SUMMARY

The Republic of Croatia, more than any other member of the European Union, depends on tourism. The Dutch Disease occurs when the rapidly growing sector that makes large inflows of foreign currency causes changes in the economy such as reallocation of production factors, ie the reallocation of workers from tradable into the non-tradable sector, the appreciation of a real effective exchange rate, high unemployment, real wage growth and deindustrialization. These changes are reflected in the Spending Effect and the Resource Movement Effect. The aim of this research was, based on the simple analysis, to investigate whether the fast growth of the tourism sector of the Croatian economy has dragged resources from other sectors and thus affected the reduction of competitiveness and de-industrialization. Data about: employees in the tradable and non-tradable sector, tourism income, real-effective exchange rate, tradable sector export and the average salaries of these two sectors were processed with a linear regression analysis based on which was concluded that the Dutch Disease did not affect Croatia. Despite this conclusion, it does not have to be that, in case of continued growth of tourism sector in Croatia, will be no negative effects of the Dutch Disease in the future.

Keywords: Dutch Disease, Tourism, "Spending Effect", "Resource Movement Effect"